



Korišćenje veštačke inteligencije za upravljanje održivom tranzicijom u vinogradarstvu „STIV“

MODUL 2: Digitalna tranzicija u vinogradarstvu

Precizno vinogradarstvo predstavlja revoluciju u upravljanju vinogradima, kombinujući napredne tehnologije, analizu podataka i agronomsko znanje kako bi se odgovorilo na klimatske, ekološke i kvalitativne izazove vinskog sektora. U ovom modulu istražićemo njegove osnove, ključne alate i praktične primene za efikasniju i održiviju proizvodnju.

Pravna napomena

Sufinansirano od strane Evropske unije. Međutim, izneti stavovi i mišljenja pripadaju isključivo autoru(ima) i ne odražavaju nužno stavove Evropske unije ili Evropske izvršne agencije za obrazovanje i kulturu (EACEA). Ni Evropska unija niti EACEA ne mogu se smatrati odgovornim za njih.

Datum: 20.02.2026.

STIV konzorcijum

université
de **BORDEAUX**



FONDAZIONE
COMUNITARIA
DI AGRIGENTO
ETRAPANI



ESCUELA
DE VITICULTURA
Y ENOLOGÍA
FÉLIX JIMÉNEZ
DE REQUENA

LaUNIO
Llauradora i Ramadera



Co-funded by
the European Union

Content

1. Uvod u precizno vinogradarstvo	2
2. Osnove digitalne vizualizacije vinograda	6
3. Pametne tehnologije za monitoring u vinogradu	8
4. Prediktivno modeliranje i napredno upravljanje podacima	14
5. Sistemi za podršku odlučivanju (DSS) u preciznom vinogradarstvu	28
6. Izazovi i mogućnosti digitalizacije u vinogradarstvu	39
7. 7. Strategic evaluation of technology adoption	46
Literatura	54
ANEKS I – Pitanja za proveru znanja	56
ANEKS II – Didaktička aktivnost: „Izbor odgovarajućih tehnologija za dve vinarije sa sličnim problemima“	59

1. Uvod u precizno vinogradarstvo

Precizno vinogradarstvo postalo je jedna od najvažnijih strategija za suočavanje sa savremenim izazovima vinskog sektora, uključujući: promene povezane sa klimatskim promenama, pritisak na prirodne resurse, potrebu za unapređenjem kvaliteta proizvoda od vinove loze, kao i zahteve potrošača u pogledu sledljivosti. Precizno vinogradarstvo zasniva se na sistematskom posmatranju, kontinuiranom merenju i intervencijama na lokalnom nivou, što omogućava prilagođeno upravljanje proizvodnjom u skladu sa fizičkim, biološkim i klimatskim specifičnostima svake podzone.


Osnovna ideja preciznog vinogradarstva jeste identifikacija i upravljanje **prostornom i unutrašnjom (intra-parcelnom) varijabilnošću vinograda**. Još od 1980-ih godina, pionirska istraživanja autora Smart (1985) i Bramley (2003) pokazala su da unutar iste parcele vinograda postoje značajne razlike u bujnosti biljaka, vlažnosti i teksturi zemljišta, izloženosti suncu i nagibu terena, što dovodi do razlika u prinosu i kvalitetu grožđa. Zanemarivanje ove heterogenosti dovodi do neefikasnog i ekološki neodrživog agronomskog upravljanja.



Slika 1. Heterogenost između parcela.
Izvor: Marcos Machado, 2022


Precizno upravljanje vinogradarstvom zasniva se na skupu tehnologija koje deluju međusobno povezano:

- **Terenski senzori**, koji mere vlažnost zemljišta, temperaturu vazduha, pritisak vodene pare ili sunčevo zračenje, mogu se postavljati na različitim dubinama i lokacijama unutar krošnje biljaka kako bi se dobili precizni i reprezentativni podaci.



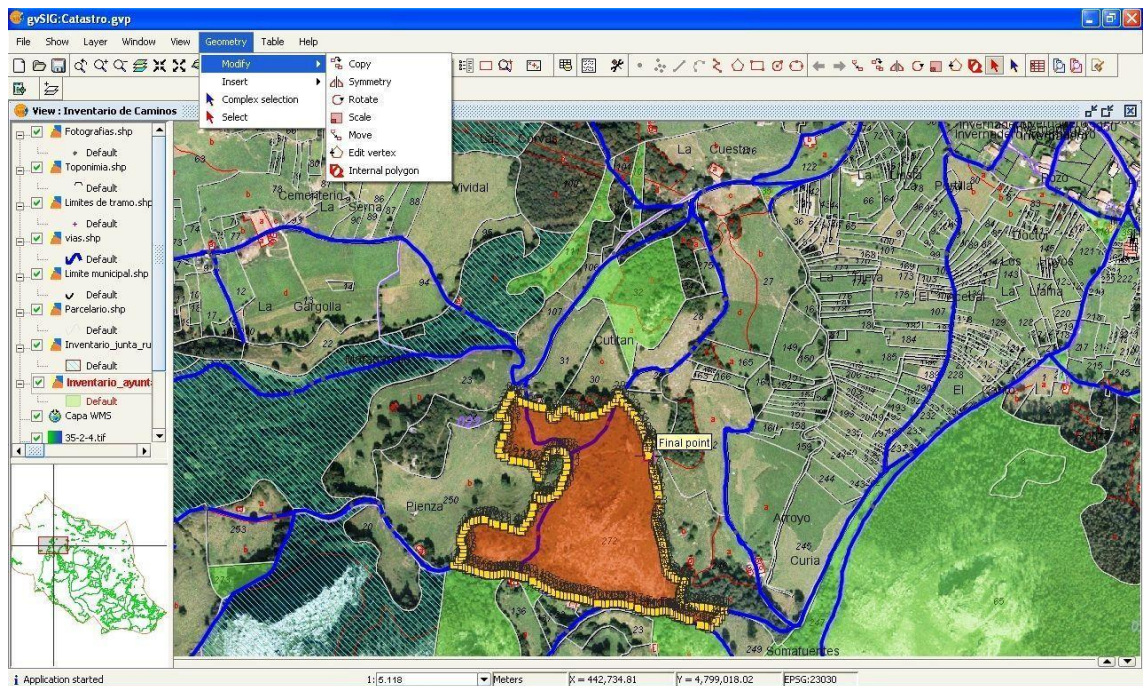
Slika 2. Terenski senzor.
Izvor: AGROTECH

- **Daljinsko osmatranje pomoću satelita i dronova** omogućava merenje indeksa kao što su NDVI (Normalized Difference Vegetation Index), SAVI ili NDRE. Sva tri indeksa koriste se za procenu vegetativne bujnosti, nutritivnog statusa i fotosintetskog potencijala biljke.




Slika 3. Daljinsko osmatranje putem satelita za analizu kvaliteta vode.
Izvor: gvSIG

- **Geografski informacioni sistemi (GIS)**, koji integrišu prostorne i vremenske podatke kako bi generisali zone upravljanja i agronomske mape preporuka, sa rezolucijama koje se kreću od 30 metara (Sentinel-2) do 2–5 cm (UAV). **Zoniranje** omogućava klasifikaciju različitih tipova zemljišta u vinogradu radi primene prilagođenog upravljanja za svaki tip. **Mape preporuka** služe za prilagođavanje đubrenja i zaštite bilja specifičnim uslovima na terenu.



Slika 4. Zoniranje parcele pomoću GIS-a.
Izvor: Environmental Method

- **Prediktivni modeli i algoritmi veštačke inteligencije**, poput neuronskih mreža, mašina podrške vektorima (SVM) i regresije slučajnih šuma (Random Forest), pretvaraju podatke u konkretne uvide i preporuke za delovanje. Njihova primena obuhvata predviđanje prinosa i kvaliteta grožđa, detekciju bolesti i određivanje potreba za navodnjavanjem.



Slika 5. Funkcionisanje veštačke neuronske mreže.
Izvor: AWS

- **Digitalne platforme za podršku odlučivanju** nude interaktivne panele, upozorenja, geopozicionirane zapise i povezivanje u realnom vremenu sa mašinama i IoT uređajima, što omogućava daljinsko upravljanje vinogradom.

Zahvaljujući ovim alatima, vinogradar može identifikovati specifične zone upravljanja (SMA) unutar vinograda i primeniti diferencirane tretmane, kao što su navodnjavanje, đubrenje, fitosanitarna zaštita ili selektivna berba, čime se optimizuje korišćenje resursa i unapređuje enološki kvalitet. Na primer, u regionima poput Napa doline (SAD) ili doline Maipo (Čile), senzori vlažnosti zemljišta i NDVI mape koriste se za uspostavljanje sektorskih sistema navodnjavanja, što je dovelo do uštede vode i do 40% bez smanjenja produktivnosti.

Od svojih početaka sa diferencijalnim GPS-om devedesetih godina, precizno vinogradarstvo evoluiralo je ka sofisticiranijim, dostupnijim i prilagodljivijim sistemima. Razvoj digitalnih tehnologija omogućio je širu primenu ovih rešenja: danas postoje pristupačni senzori, dronovi, open-source softveri i cloud platforme koje omogućavaju njihovu primenu i na malim i srednjim gazdinstvima. Projekti poput VineScout (Španija), GrapeLook (Južna Afrika) ili Vintel (Francuska) pokazali su efikasnost ovih alata u različitim zemljišnim i klimatskim uslovima (Baluja et al., 2012; Matese & Di Gennaro, 2015).

Pored toga, precizno vinogradarstvo doprinosi i zaštiti životne sredine smanjenjem upotrebe pesticida, optimizacijom potrošnje vode i očuvanjem biodiverziteta. Njegova integracija sa regenerativnom poljoprivredom, organskim vinogradarstvom i sertifikatima kao što je HVE (Haute Valeur Environnementale) dodatno potvrđuje njegovu ulogu kao ključnog alata u ekološkoj tranziciji sektora.

Iz svih ovih razloga, precizno vinogradarstvo predstavlja osnovu za razvoj pametnijeg, otpornijeg i održivijeg vinogradarstva. Ono ne zamenjuje znanje vinogradara, već ga unapređuje pružajući objektivnu i ažurnu osnovu za donošenje odluka. U kontekstu digitalne transformacije evropske poljoprivrede, ova disciplina predstavlja jedan od ključnih faktora za ostvarenje ciljeva Evropskog zelenog dogovora, strategije „Od njive do trpeze“ i digitalizacije ruralnih područja.

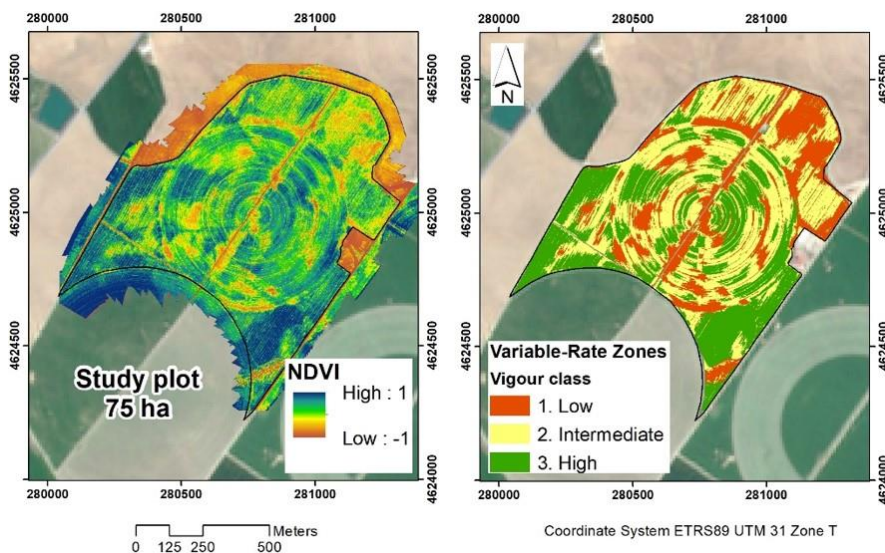
2. Osnove digitalne vizualizacije vinograda

Jedan od glavnih izazova preciznog vinogradarstva ne odnosi se samo na prikupljanje podataka, već i na njihovu analizu i interpretaciju. Kako vinarije sve više koriste senzore, meteorološke stanice, satelitske snimke i istorijske podatke, količina informacija kontinuirano raste i zahteva obradu kako bi se pretvorila u korisno znanje. U tom smislu, alati za vizualizaciju podataka i prediktivni modeli imaju ključnu ulogu u donošenju informisanih odluka, posebno kada su integrisani u digitalne tokove rada – od prikupljanja podataka do konkretnih agronomskih mera.

Vizualizacija podataka u vinogradarstvu

Vizualizacija podataka predstavlja način grafičkog i jasnog prikaza kvantitativnih informacija prikupljenih u vinogradu. Korišćenjem tematskih mapa, interaktivnih grafikona, 3D modela i kontrolnih panela (dashboard-a), olakšava se razumevanje složenih pojava kao što su prostorna varijabilnost, sezonske promene, mikroklimatski uslovi, gustina izdanaka ili indeks lisne površine. Drugim rečima, vizualizacija pretvara velike količine tehničkih podataka u vizuelno znanje koje mogu razumeti tehničari, poljoprivrednici i vinari, bez potrebe za naprednim znanjem iz analize podataka.

Geografski informacioni sistemi (GIS) predstavljaju ključne alate za vizualizaciju prostornih podataka. Kroz mape bujnosti (NDVI), vlažnosti zemljišta, prinosa, pojave bolesti ili toplotnog stresa, vinogradari mogu prepoznati obrasce i identifikovati kritične zone unutar svojih parcela.



Slika 6. Levo: NDVI dobijen multispektralnim snimanjem iz marta 2019. godine za procenu razvoja ječma i određivanje varijabilne doze đubrenja. Desno: zone varijabilnog đubrenja.
Izvor: Jensen i sar. (2011)

U praksi su razvijene konkretne aplikacije kao što je VineView, koja omogućava kontinuirani vizuelni nadzor vinograda uz automatsko zoniranje, kao i rešenja poput Cropio i AgriWebb, koja integrišu podatke sa senzora, mašina i vremenskih uslova kako bi kreirala digitalne modele u realnom vremenu. Na evropskom nivou, inicijative poput FutureFarm i SmartAgriHubs značajno su doprinele razvoju interoperabilnih platformi za agronomsku vizualizaciju.

Pored toga, alati za poslovnu analitiku kao što su Power BI, Tableau ili Qlik Sense omogućavaju integraciju podataka iz različitih izvora – senzora, meteoroloških podataka i analiza zemljišta i njihov prikaz kroz prilagodljive kontrolne panele (dashboard-e). Ovi paneli mogu biti podešeni za automatsko slanje upozorenja, generisanje periodičnih izveštaja ili simulaciju različitih scenarija upravljanja. Danas postoje i specijalizovane platforme za vinogradarstvo, poput VineSignal, Farm360 ili Datagrapes, koje nude funkcionalnosti kao što su geolokacija, upravljanje partijama, poređenje kroz vreme i istorijska analiza.

Vizualizacija ne samo da unapređuje donošenje odluka, već i olakšava komunikaciju između tehničara, vinara, radnika na terenu i menadžera, omogućavajući koordinisanje i informisanje upravljanje. U savremenim vinarijama, vizuelni paneli su često integrisani u kontrolne centre i ažuriraju se u realnom vremenu zahvaljujući povezivanju sa meteorološkim stanicama, sensorima i mehanizacijom.

Prediktivno modeliranje i napredna analitika

Prediktivno modeliranje zasniva se na upotrebi statističkih algoritama i veštačke inteligencije za predviđanje budućeg ponašanja vinograda na osnovu različitih prikupljenih podataka. Ovakav pristup omogućava prelazak sa reaktivnog na proaktivno upravljanje, kroz anticipaciju rizika i optimizaciju resursa. U uslovima klimatskih promena, mogućnost predviđanja različitih scenarija postaje značajna konkurentna prednost.

Postoji više tipova modela koji se koriste u vinogradarstvu:

1. **Fenološki modeli** - predviđaju ključne faze razvoja vinove loze, kao što su kretanje pupoljaka, cvetanje, šarka i sazrevanje. Zasnivaju se na klimatskim parametrima poput akumulirane temperature (stepen-dani), dužine dana i relativne vlažnosti. Alati kao što su Phenoclim, VitiMeteo i STICS omogućavaju precizno planiranje radova.
2. **Fitosanitarni modeli** - predviđaju pojavu bolesti kao što su plamenjača (Plasmopara viticola), pepelnica (Uncinula necator) i siva trulež (Botrytis cinerea). Oslanjaju se na podatke o temperaturi, vlažnosti lista i padavinama, uz modele poput Goidanich ili Broome.
3. **Vodeni modeli** – procenjuju vodni balans zemljišta i stres biljke korišćenjem senzora, meteoroloških podataka i karakteristika zemljišta. Modeli kao što su AquaCrop ili Hydrus omogućavaju precizno planiranje navodnjavanja i smanjenje potrošnje vode.

4. **Modeli prinosa i kvaliteta** - procenjuju očekivani prinos i parametre kvaliteta grožđa (šećer, kiselost, antocijani). Koriste se metode mašinskog učenja poput linearne regresije, stabala odlučivanja, neuronskih mreža i Random Forest modela, sa visokom preciznošću predviđanja.
5. **Digitalni blizanci (Digital twins)** - predstavljaju digitalnu repliku vinograda koja integriše sve podatke u jedinstven sistem i omogućava simulaciju budućih scenarija. Projekti poput SmartVitiNet, VINIoT i DIGIWINE razvijaju ove sisteme za planiranje i upravljanje.
6. **Integrirani socio-ekonomski modeli** - kombinuju agronomske, ekonomske i tržišne faktore kako bi procenili finansijski efekat različitih odluka. Posebno su važni za zadruge, velike vinarije i kreatore politika.

Izazovi i buduće perspektive

Uprkos značajnom napretku, efikasna primena ovih tehnologija suočava se sa brojnim izazovima:

- • Kvalitet, homogenost i standardizacija podataka ključni su za dobijanje pouzdanih modela.
- • Neophodno je napredno tehničko i agronomsko znanje kako bi se rezultati pravilno interpretirali i izbegle greške u donošenju odluka.
- • Interoperabilnost između različitih digitalnih platformi i uređaja različitih proizvođača i dalje predstavlja tehničko i tržišno ograničenje.
- • Početna ulaganja mogu biti visoka, naročito za mala gazdinstva, iako se koristi ostvaruju na srednji i duži rok.

U budućnosti se očekuje veća integracija platformi, razvoj digitalnih agrarnih asistenta (AgBots) i šira primena generativne veštačke inteligencije za simulaciju agronomskih scenarija. Takođe, biće sve zastupljeniji neinvazivni senzori, algoritmi koji se samostalno prilagođavaju i blockchain tehnologije za obezbeđivanje sledljivosti i integriteta podataka, čime će se dodatno unaprediti transparentnost u lancu vrednosti vina.

3. Pametne tehnologije za monitoring u vinogradu

Pametni monitoring u vinogradarstvu predstavlja „senzorni sistem“ digitalnog vinograda – integrisanu mrežu uređaja i tehnologija koje kontinuirano i precizno prikupljaju podatke o stanju zemljišta, biljaka i okruženja. Ovakav automatizovan i skalabilan sistem omogućava pravovremeno prepoznavanje nepovoljnih uslova, optimizaciju resursa i donošenje informisanih odluka. U nastavku su detaljno predstavljene glavne komponente ovog sistema, uz primere iz prakse i reference koje potvrđuju njegovu efikasnost.


3.1 Wireless sensor networks on the ground

Bežične senzorske mreže (WSN) predstavljaju jednu od najvažnijih inovacija u preciznom vinogradarstvu, jer omogućavaju kontinuirano i precizno praćenje stanja zemljišta u realnom vremenu. Ove mreže zasnivaju se na

postavljanju pametnih senzorskih čvorova na strateškim lokacijama unutar vinograda, koji su međusobno povezani putem tehnologija niske potrošnje energije, kao što su LoRaWAN ili Zigbee. Sensori prikupljaju podatke o ključnim parametrima, poput vlažnosti zemljišta, temperature, električne provodljivosti i pH vrednosti, a zatim ih prenose ka centralnim sistemima za obradu, kao što su bazne stanice i cloud platforme.

Primena ovih tehnologija pokazala je značajne praktične koristi. U vinogradarskim regionima poput La Riohe omogućeno je preciznije upravljanje navodnjavanjem, što je dovelo do smanjenja potrošnje vode i bolje usklađenosti sa klimatskim i zemljišnim uslovima. U pojedinim delovima Francuske, ovakvi sistemi korišćeni su za rano otkrivanje mraza i aktiviranje sistema upozorenja, čime se vinogradarima omogućava brza reakcija bez potrebe za stalnim fizičkim prisustvom na terenu.

Prednosti ovih mreža ogledaju se u niskim operativnim troškovima, visokom stepenu energetske autonomije i mogućnosti prilagođavanja različitim konfiguracijama terena. Ipak, njihova efikasna primena zahteva pažljivo planiranje rasporeda senzora, redovnu kalibraciju i proveru kvaliteta bežične komunikacije, posebno u vinogradima sa složenim reljefom ili velikim površinama.



Slika 7. Arhitektura bežične senzorske mreže.


Izvor: Bolivar et al.

3.2 Daljinsko osmatranje pomoću dronova i satelita

Daljinsko osmatranje iz vazduha značajno je unapredilo upravljanje vinogradima, omogućavajući precizno, učestalo i skalabilno mapiranje. Sateliti

obezbeđuju redovno pokrivanje, na dnevnom ili nedeljnom nivou, što je naročito korisno za praćenje većih površina, dok dronovi (UAS) omogućavaju snimanja po potrebi, uz vrlo visoku prostornu rezoluciju od 2–5 cm, što je ključno za donošenje odluka na nivou pojedinačnih parcela.

Korišćenjem multispektralnih kamera, koje obuhvataju vidljivi, blisko-infracrveni i termalni spektar, kao i naprednijih hiperspektralnih senzora, moguće je izračunati različite vegetacione indekse poput NDVI, NDRE, SAVI ili GI. Ovi indikatori omogućavaju procenu bujnosti biljaka, detekciju vodnog stresa, određivanje fenološkog stadijuma i uočavanje nutritivnih nedostataka koji nisu vidljivi golim okom.



Slika 8. Daljinsko osmatranje pomoću drona. Izvo: Cielito Drone Enterprise

Određeni primeri iz prakse jasno pokazuju agronomski značaj ovih tehnologija. Na vinogradarskim gazdinstvima, kombinacija termalnih i multispektralnih snimaka omogućila je pravovremeno prepoznavanje bolesti poput botritisa, kao i pojave vodnog stresa, i to nekoliko dana pre nego što postanu vidljivi. Takođe, pokazano je da redovno, nedeljno integrisanje mapa u GIS platforme olakšava donošenje odluka o optimalnom vremenu berbe, što doprinosi ujednačenijem kvalitetu vina.

U novije vreme, primena veštačke inteligencije u kombinaciji sa spektralnim podacima omogućava još ranije otkrivanje štetočina, plamenjače ili pepelnice, čak i pre pojave vidljivih simptoma. Algoritmi zasnovani na neuronskim mrežama analiziraju specifične spektralne opsege i generišu geopozicionirane mape rizika, koje služe kao osnova za precizno planiranje intervencija u vinogradu.

3.3 Mreže meteoroloških stanica visoke rezolucije

Pored direktnog praćenja zemljišta i biljaka, meteorološke mreže imaju ključnu ulogu u donošenju agronomskih odluka. Automatizovane meteorološke stanice, opremljene sensorima za temperaturu, relativnu vlažnost, sunčevo zračenje, atmosferski pritisak, padavine i brzinu vetra, omogućavaju detaljno i kontinuirano praćenje mikroklimatskih uslova u vinogradu.

Ovi sistemi omogućavaju primenu prediktivnih modela za rano prepoznavanje fitosanitarnih rizika, poput pojave plamenjače ili botritisa, kroz automatsko detektovanje uslova koji pogoduju razvoju bolesti. Na osnovu tih podataka, vinogradari mogu preciznije planirati vreme i učestalost tretmana, čime se izbegava nepotrebna primena zaštitnih sredstava. U praksi, ovakav pristup doveo je do smanjenja upotrebe fungicida i do 30%, uz očuvanje efikasnosti zaštite.



Meteorološka stanica za vinogradarstvo. Source: Meteosierra

Pored toga, meteorološke stanice omogućavaju predviđanje ekstremnih klimatskih događaja, kao što su prolećni mrazovi ili epizode toplotnog stresa. Njihova integracija sa automatizovanim sistemima pokazala je da može smanjiti gubitke u proizvodnji za više od 40%, zahvaljujući pravovremenom aktiviranju sistema zaštite od mraza, poput prskalica ili grejača.

Kada se povežu sa sensorima u zemljištu i na biljkama, ove stanice zatvaraju ciklus digitalnog praćenja vinograda, pružajući sveobuhvatan, višeslojni i prediktivni uvid koji unapređuje otpornost i održivost upravljanja vinogradima.

3.4 Senzori lista i biljnog soka

U preciznom vinogradarstvu nije dovoljno razumeti ponašanje zemljišta – ključno je znati kako biljka fiziološki reaguje na uslove okruženja. U tu svrhu koriste se specijalizovani senzori koji u realnom vremenu prate pokazatelje stresa i potrošnje vode kod vinove loze.

Senzori lista, koji mere turgorski pritisak, omogućavaju rano otkrivanje vodnog stresa, čak i pre nego što se on manifestuje u zemljištu. Ovakav pristup omogućava pravovremeno planiranje navodnjavanja, zasnovano na stvarnim potrebama biljke, a ne isključivo na parametrima zemljišta ili klime. Ovi uređaji pokazali su se posebno korisnim tokom toplotnih talasa i dugotrajnih suša.



Slika 10. Folijarni senzor za detekciju gubitka vode. Izvor: Um Só Planeta

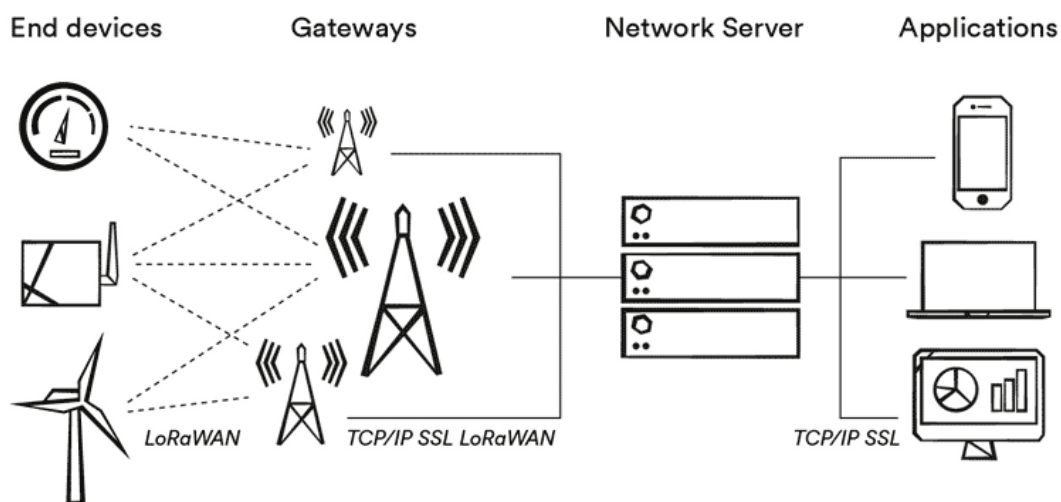
S druge strane, senzori protoka biljnog soka mere količinu vode koja se transportuje od korena ka krošnji biljke. Ovi podaci odražavaju stvarnu potrošnju vode i omogućavaju optimizaciju navodnjavanja u skladu sa realnim potrebama vinove loze. U eksperimentima sa sortama Chardonnay i Cabernet Sauvignon, njihova primena omogućila je smanjenje potrošnje vode bez negativnog uticaja na sazrevanje, uz istovremeno poboljšanje ujednačenosti kiselosti i koncentracije fenolnih jedinjenja u širi.

Obe tehnologije omogućavaju prelazak sa tradicionalnog upravljanja navodnjavanjem zasnovanog na kalendaru ili podacima iz zemljišta ka strategiji koja se temelji na stvarnom i dinamičkom odgovoru biljke, čime se povećava efikasnost korišćenja vode i unapređuje enološki kvalitet.

3.5 Integrativne platforme i poljoprivredni IoT

Prava vrednost digitalnih tehnologija u vinogradarstvu dolazi do izražaja tek kada se integrišu u jedinstvenu i koherentnu arhitekturu koja omogućava da se raspršeni podaci pretvore u precizne i automatizovane agronomske odluke.

Napredne platforme objedinjuju informacije sa senzora vlažnosti zemljišta, meteoroloških stanica, dronova i satelita u okviru jedinstvenog interfejsa. Ova integracija omogućava prikaz dinamičkih mapa vodnog stresa (CWSI), vegetativne bujnosti, zdravstvenog stanja biljaka i raspodele štetočina. Na osnovu prilagođenih algoritama, sistem predlaže konkretne mere upravljanja, kao što su sektorsko navodnjavanje, primena fitosanitarnih tretmana ili slanje preventivnih upozorenja. Takođe, sistemi se mogu povezati sa automatizovanim sistemima za navodnjavanje putem pametnih ventila, koji se aktiviraju u skladu sa unapred definisanim pragovima.



Slika 11. LoRaWAN sistem.

Izvor: Actility

U područjima sa ograničenom povezanošću, komunikacione mreže dugog dometa i niske potrošnje energije (LoRaWAN) pokazale su sposobnost da održavaju rad monitoring stanica autonomno i duže od godinu dana, uz redovan prenos podataka, bez potrebe za spoljnim izvorima električne energije.

Aktuelni trend ide ka razvoju kolaborativnih i otvorenih platformi, gde različiti akteri u sektoru dele podatke u cilju poređenja rezultata (benchmarking), teritorijalnog praćenja i primenjenih istraživanja. Ova sinergija ne samo da povećava efikasnost pojedinačnih gazdinstava, već i stvara kolektivnu inteligenciju za donošenje odluka na regionalnom nivou.

4. Prediktivno modeliranje i napredno upravljanje podacima

Transformacija agronomskih podataka u upotrebljive informacije predstavlja osnovu digitalnog vinograda. Korišćenjem naprednih sistema za vizualizaciju i prediktivnog modeliranja, vinogradari mogu da predvide trendove, procene rizike, planiraju aktivnosti i unaprede kako kvalitativne, tako i ekonomske rezultate svake proizvodne sezone. U ovom poglavlju objašnjava se način funkcionisanja ovih alata, tehnologije koje koriste, rezultati koje omogućavaju i njihova praktična primena.


4.1 Geografski informacioni sistemi (GIS) i interaktivne mape

Geografski informacioni sistemi (GIS) predstavljaju ključni alat preciznog vinogradarstva, jer omogućavaju integraciju i analizu različitih slojeva prostornih podataka. Ovi slojevi uključuju nadmorsku visinu, mape bujnosti zasnovane na vegetacionim indeksima (poput NDVI), pedološke karte, lokalne klimatske podatke i istorijske prinose parcela. Na osnovu ovih informacija moguće je kreirati mape preporuka koje definišu specifične zone upravljanja (SMA), čime se omogućava diferencirano donošenje odluka o navodnjavanju, đubrenju, zaštiti bilja i selektivnoj berbi.

U Evropi postoji niz primera primene ovih sistema. U Španiji, platforme poput SIGPAC-a i Geoportala Nacionalnog geografskog instituta omogućavaju vinogradarima i stručnjacima pristup podacima o parcelama i njihovo povezivanje sa pedološkim i topografskim slojevima. U Francuskoj, regioni poput Bordoa i Burgundije razvili su sisteme mapiranja terroira, kao što je Vitimap, koji integrišu klimatske i zemljišne podatke radi procene pogodnosti za vinogradarstvo. U Portugalu, projekat VineGIS u dolini Duro kombinuje GIS sa senzorima i satelitskim osmatranjem za integrisano upravljanje vinogradima. U Italiji, inicijative poput WineGIS-a u Toskani i Pijemontu omogućile su povezivanje sorti grožđa sa karakteristikama zemljišta, klimom i praksama upravljanja.

Na nivou Evrope, program Copernicus i satelitski snimci Sentinel-2 predstavljaju ključan izvor podataka za redovno praćenje vinograda, omogućavajući izradu mapa bujnosti i identifikaciju varijabilnosti unutar parcela. Istovremeno, komercijalne platforme poput Terranis (Francuska) ili EviWine (Italija/Španija) nude integrisana rešenja koja povezuju GIS, satelitske podatke i prediktivne modele radi optimizacije upotrebe resursa.

U novije vreme, primena hiperspektralnih snimaka dobijenih dronovima, u kombinaciji sa tehnikama mašinskog učenja, omogućava detekciju kritičnih zona u vinogradima bez potrebe za manuelnim analizama. Ove inovacije značajno smanjuju vreme obrade podataka i povećavaju preciznost u definisanju zona upravljanja, doprinoseći održivijem i efikasnijem korišćenju resursa u evropskom vinogradarstvu.



Slika 12. Peta godišnjica satelita Sentinel-2. Izvor: AIRBUS

4.2 Kontrolni paneli (dashboard-i) i digitalne platforme

Savremene digitalne platforme ne prikazuju više samo statične mape, već pretvaraju podatke sa senzora i daljinskog osmatranja u interaktivna vizuelna rešenja dostupna putem računara, tableta ili mobilnih telefona. Ovi alati omogućavaju vinogradarima da upravljaju proizvodnjom dinamično i na osnovu podataka u realnom vremenu, čime se značajno unapređuje preciznost odlučivanja i efikasnost rada.

Najvažnije funkcionalnosti ovih sistema uključuju:

- **Interaktivne vremenske grafikone** - prikazuju kretanje ključnih pokazatelja kao što su NDVI, vlažnost zemljišta, temperatura vazduha i nivo vodnog stresa.
- **Geopozicionirana upozorenja** - klasifikovana prema nivou rizika (nizak, srednji, visok), uz konkretne preporuke, poput: „aktivirati sistem navodnjavanja u sektoru A ili „primeniti hitan fitosanitarni tretman“.
- **Uparednu analizu sezona** - omogućava poređenje različitih proizvodnih ciklusa i identifikaciju odstupanja u razvoju vinograda.
- **Digitalnu evidenciju aktivnosti** - beleženje intervencija kao što su navodnjavanje, zaštita bilja i berba, uz precizne podatke o datumu, količini i lokaciji, čime se unapređuje buduće odlučivanje.

Platforme kao što su vite.net® ili AgriWebb omogućavaju upravljanje kompletnim proizvodnim ciklusom direktno putem mobilnih uređaja. U evropskim pilot projektima pokazano je da interfejsi razvijeni u saradnji sa

korisnicima mogu smanjiti vreme potrebno za interpretaciju agronomskih podataka i do 40% (CORDIS, 2023).

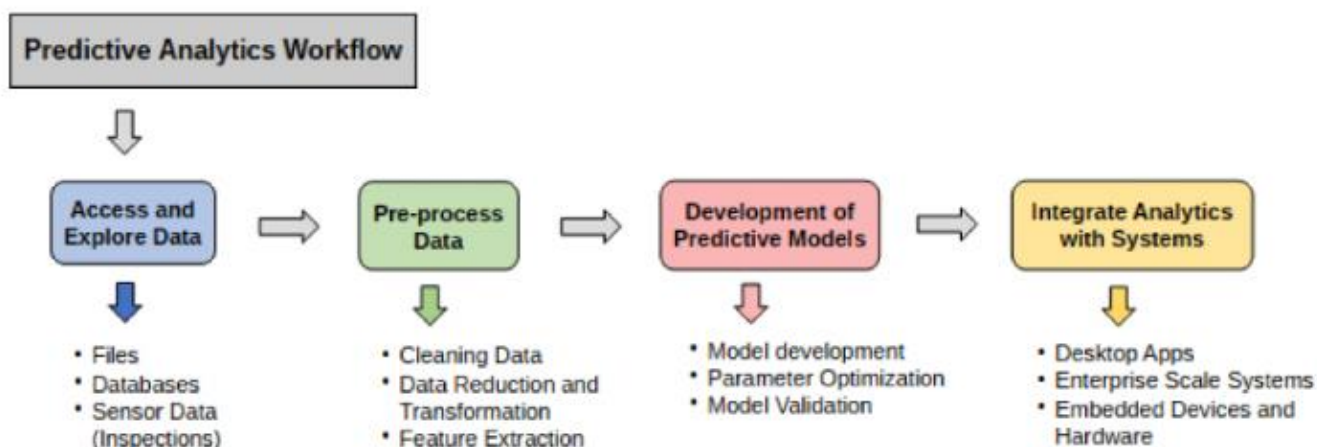


Slika 13. Upravljanje u realnom vremenu putem mobilnog uređaja. Izvor: AgriWebb

4.3 Prediktivni modeli i algoritmi veštačke inteligencije

Predviđanje prinosa

U okviru preciznog vinogradarstva, **predviđanje prinosa** postalo je ključan alat ne samo za agronomsko planiranje, već i za **logističko, komercijalno** i **finansijsko upravljanje** vinogradarskim gazdinstvima. Integracija tehnika mašinskog i dubokog učenja u analizu podataka iz različitih izvora – satelitskih snimaka, klimatskih parametara, senzora na terenu i istorijskih evidencija – omogućava vrlo precizno predviđanje količine grožđa i različitih pokazatelja kvaliteta u različitim fazama fenološkog ciklusa.

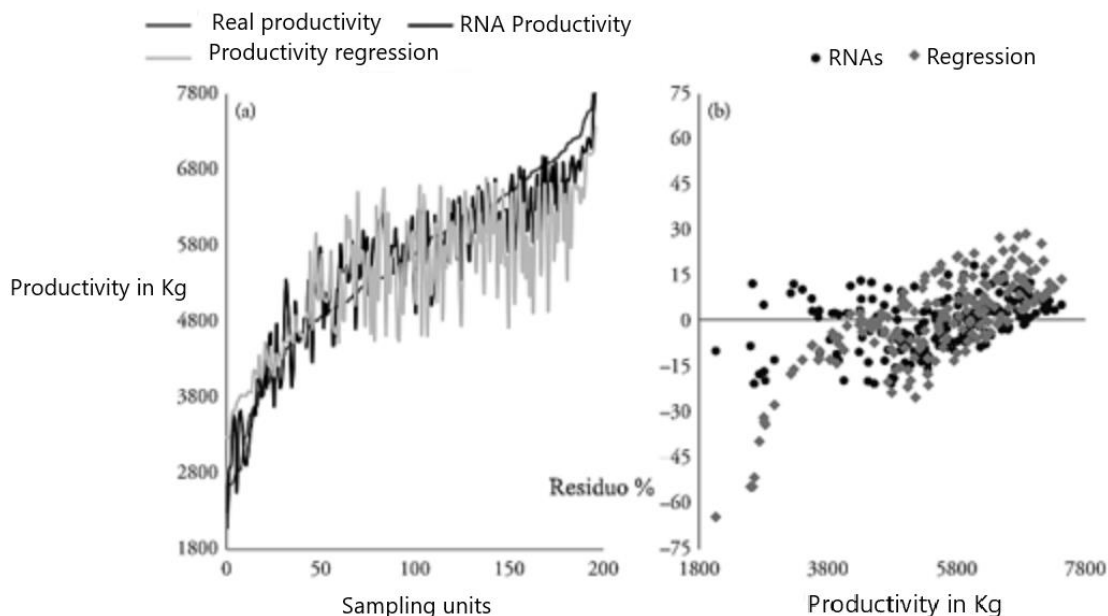


Slika 14. Tok prediktivne analitike. Izvor: Silva et al, 2021

Predviđanje prinosa pomoću neuronskih mreža

Jedan od najperspektivnijih pristupa u predviđanju prinosa u vinogradarstvu jeste primena **LSTM (Long Short-Term Memory)** mreža, koje predstavljaju posebnu vrstu rekurentnih neuronskih mreža sposobnih za obradu vremenskih serija. Ovi modeli integrišu podatke poput meteoroloških parametara, vegetacionih indeksa i fenoloških faza, omogućavajući precizno modeliranje razvoja vinograda kroz vreme. Istraživanje sprovedeno u regionu **Alto Douro u Portugalu**, koje je koristilo LSTM modele na osnovu **Sentinel-2** snimaka (posebno NDVI indeksa) i istorijskih klimatskih podataka, pokazalo je visoku tačnost predviđanja, sa **srednjom apsolutnom greškom (MAE) od 672 kg/ha i odstupanjem od svega 8%** u odnosu na stvarne rezultate tokom berbe 2020. godine. Model je uspešno testiran u različitim opštinama, potvrđujući njegovu vrednost u planiranju berbe nekoliko nedelja unapred (Fernandes et al., 2022).

Napredniji modeli, poput **CMAViT (Crop Monitoring and Assessment for Viticulture)**, dodatno unapređuju preciznost integracijom višeslojnih podataka, uključujući klimatske uslove, agronomske prakse, satelitske snimke i ekspertske znanje. Ovaj model koristi **Vision Transformer (ViT)** arhitekturu, savremeni pristup koji obrađuje slike kao sekvence podataka, slično načinima obrade u jeziku i signalima. U validacijama sprovedenim u južnoj Evropi, **CMAViT je postigao koeficijent determinacije (R^2) od 0,84 i srednju procentualnu grešku (MAPE) od 8,2%**, značajno nadmašujući tradicionalne modele poput linearne regresije ili stabala odlučivanja (Gomes et al., 2023).




Slika 15. Prediktivno modeliranje podataka. I: Eduardo Berra Villaseñor

Rano otkrivanje bolesti i stresa biljaka

Rana identifikacija bolesti vinove loze predstavlja jednu od najvažnijih primena veštačke inteligencije u vinogradarstvu. Obradom multispektralnih snimaka dobijenih dronovima (UAV) i njihovom analizom pomoću **konvolucionih neuronskih mreža (CNN)**, moguće je detektovati početne simptome bolesti kao što su **plamenjača (Plasmopara viticola)** ili **botritis (Botrytis cinerea)** sa preciznošću većom od **92% na nivou piksela**, čak i pre pojave vidljivih simptoma na terenu (Kerkech et al., 2020).

Ovi modeli, trenirani na označenim snimcima iz različitih proizvodnih sezona, omogućavaju generisanje **geopozicioniranih mapa rizika**. Na taj način se omogućavaju precizne, lokalizovane fitosanitarne intervencije, čime se smanjuje nepotrebna upotreba fungicida i unapređuje zdravstvena sledljivost vinograda.



Slika 16. Dijagnostika bolesti lista pomoću veštačke inteligencije. Izvor: Elsherbiny et al.

Procena kvaliteta ploda

Pored prinosa i zdravstvenog stanja vinograda, veštačka inteligencija se sve više koristi i za **predviđanje kvaliteta grožđa**, posebno parametara kao što su sadržaj šećera (**°Brix**), **ukupna kiselost**, **polifenoli** i aromatski potencijal. Kombinovanjem višetemporalnih NDVI snimaka dobijenih dronovima, podataka sa folijarnih senzora i laboratorijskih analiza, brojna istraživanja uspešno su procenila vrednosti ovih pokazatelja.

U jednom novijem eksperimentu korišćeni su **AutoML (Automated Machine Learning) algoritmi** za predviđanje °Brix vrednosti na osnovu NDVI indeksa iz različitih fenoloških faza. Algoritmi poput **Support Vector Machines**

(SVM), **polinomijalne regresije** i **Extra Trees Regressor** modela ostvarili su koeficijent determinacije u rasponu od $R^2 = 0,44$ do $0,53$, što se smatra zadovoljavajućim rezultatima imajući u vidu veliku varijabilnost zemljišta i fiziologije biljaka unutar parcela (Silva et al., 2021). Iako su ovi modeli još u fazi razvoja, oni otvaraju mogućnost **diferencirane berbe prema kvalitetu**, gde se najkvalitetniji grozdovi usmeravaju ka premium vinifikaciji, čime se povećava ukupna profitabilnost vinograda.

4.4 Mape preporuka i VRT tehnologija

Prediktivni modeli u vinogradarstvu ne završavaju se samo na analizi podataka, već dovode do konkretne operativne primene kroz **mape preporuka**. Ove digitalne mape predstavljaju **prostornu interpretaciju analitičkih rezultata**, definišući **tačne doze inputa** – vode, đubriva ili sredstava za zaštitu bilja – u skladu sa **specifičnim zonama upravljanja (SMA)** unutar vinograda.

Mape se najčešće izrađuju pomoću GIS platformi i mogu se eksportovati u standardnim formatima kao što su shapefile ili GeoTIFF, koji su kompatibilni sa savremenom poljoprivrednom mehanizacijom. Na taj način, **traktori, prskalice ili sistemi za fertirigaciju opremljeni VRT (Variable Rate Technology)** sistemima mogu automatski primenjivati različite količine inputa u zavisnosti od potreba svake zone u vinogradu.

Prednosti i potvrđeni rezultati

Brojna istraživanja u Evropi i Americi potvrđuju konkretne koristi primene mapa preporuka i VRT tehnologije. Studija **Zajedničkog istraživačkog centra Evropske unije (JRC)** u vinogradima Španije, Italije i Nemačke pokazala je **smanjenje upotrebe đubriva i pesticida za 20–30%**, uz istovremeno **smanjenje površinskog oticanja i zagađenja podzemnih voda** (Vendrell et al., 2020). Takođe, lokalizovana primena doprinela je **ujednačenijoj bujnosti i prinosu**, što je rezultiralo boljim enološkim kvalitetom.

U **Argentini**, u regionu Mendoza, primena traktora sa VRT sistemima zasnovanim na mapama azota dobijenim dronovima i folijarnim senzorima omogućila je **smanjenje upotrebe azotnih đubriva za 25%**, bez negativnog uticaja na razvoj biljaka ili kvalitet grožđa. Istovremeno je zabeleženo povećanje efikasnosti korišćenja azota (NUE) i smanjenje gubitaka ispiranjem (Castro et al., 2021).

U **Čileu i južnoj Francuskoj**, **pametne prskalice** opremljene kamerama za računalni vid omogućile su detekciju ranih simptoma pepelnice i plamenjače. Sistem je aktivirao mlaznice samo na zaraženim delovima vinograda, što je dovelo do **smanjenja upotrebe fungicida i do 40%**, bez narušavanja efikasnosti

zaštite (Guillén et al., 2022). Ovakav pristup takođe doprinosi smanjenju ostataka hemikalija u proizvodima i unapređuje održivost proizvodnje.

Ovi primeri jasno pokazuju da kombinacija **prediktivnog modeliranja, digitalnog mapiranja i napredne mehanizacije** uvodi novi model upravljanja vinogradima – precizan, prilagođen, efikasan i ekološki održiv.



Slika 17. Green Patrol automatski dozator za kontrolu štetočina.

Izvor: SmartProtect

4.5 Automatizovane akcije: povezivanje predikcije i intervencije

Najnapredniji nivo digitalnog vinogradarstva dostiže se kada se u potpunosti zatvori ciklus upravljanja **agronomskim podacima**, odnosno kada podaci prikupljeni senzorima i obrađeni kroz prediktivne modele **direktno dovode do automatizovanih ili poluautomatizovanih odluka** koje se sprovode na terenu putem povezanih sistema. Ovaj pristup, poznat kao „**od podataka do akcije**“, predstavlja vrhunac preciznog upravljanja vinogradima, jer objedinjuje monitoring u realnom vremenu, veštačku inteligenciju i automatizaciju poljoprivrednih procesa.

U ovom modelu, sistemi za **podršku odlučivanju (DSS)** više nisu samo alati za analizu i pregled podataka, već **operativne platforme koje mogu direktno upravljati fizičkim uređajima** - od ventila za navodnjavanje do automatizovanih sistema za berbu. Na taj način omogućavaju se **brze, objektivne i kontinuirane**

reakcije zasnovane na podacima, uz smanjenje kašnjenja i oslanjanja na subjektivnu procenu.

Funkcionalni primeri pametne automatizacije

1. **Automatska aktivacija navodnjavanja:** U savremenim vinogradima, sistemi za navodnjavanje kap po kap povezani su sa meteorološkim stanicama i senzorima vlažnosti zemljišta. Kada vrednosti vlage padnu ispod unapred definisanih pragova, DSS sistem automatski šalje signal za aktivaciju ventila, i to samo u zonama gde je potrebno i u optimalnom trajanju. Platforme poput **SmartVitis** i **iRoom** već implementiraju ovakva rešenja u vinogradima u Italiji i Kaliforniji, gde su ostvarene uštede vode i do **30%**, bez negativnog uticaja na prinos i kvalitet grožđa (Matese & Di Gennaro, 2021).



Slika 18. Automatizovano navodnjavanje. Izvor: verdeesvida

2. **Automatska upozorenja i aktivacija mehanizacije:** Napredni sistemi za upravljanje poljoprivredom šalju **trenutna obaveštenja o fitosanitarnim rizicima koje detektuju prediktivni modeli**, kao što su uslovi pogodni za razvoj plamenjače ili botritisa. Ova upozorenja mogu biti podešena tako da, uz odobrenje operatera, direktno aktiviraju **autonomne prskalice ili traktore vođene GPS-om**, ili da omoguće donošenje brzih i informisanih odluka od strane odgovornog stručnjaka. Jedan od primera je sistem **CropX**, koji integriše analizu krošnje, klimatske podatke i prognoze kako bi generisao upozorenja na nivou parcele koja mogu pokrenuti konkretne intervencije (CropX, 2023).

Advanced agricultural management systems send **immediate notifications of phytosanitary risks detected by predictive models**, such as favorable conditions for mildew or botrytis. These alerts can be configured to directly trigger **autonomous sprayers or GPS-guided tractors**, if authorized by the operator, or allow real-time informed

decision-making by the responsible technician. One example is the **CropX** system, which integrates canopy analysis, climate data, and forecasts to generate triggerable alerts at the plot level (CropX, 2023).



Slika 19. Alat Crop za obaveštavanje o upozorenjima..

Izvor: Cropx

3. **Segmentirana berba na osnovu diferencirane zrelosti:** Selektivna **berba po zonama zrelosti** predstavlja jednu od najnaprednijih primena u preciznom vinogradarstvu. Sistemi za podršku odlučivanju (DSS), koristeći NDVI snimke i optičke senzore koji mere **boju, sadržaj hlorofila i indeks rastvorljivih materija (°Brix)**, mogu precizno odrediti trenutak kada svaka zona upravljanja dostigne optimalnu zrelost. Na osnovu tih informacija, berba se može organizovati u fazama ili **čak automatizovati putem savremenih mašina opremljenih hiperspektralnim kamerama** koje u realnom vremenu prepoznaju i biraju zrele grozdove. Neki modeli **pametnih berača, poput New Holland Braud 9090X**, već integrišu senzore za procenu kvaliteta ploda, što omogućava ovakav nivo automatizacije (New Holland, 2022).



Slika 20. SCF senzor hlorofila za in-situ merenje na terenu. Izvor: innova

Pionirski evropski projekti

Evropski projekti poput **AI GRAPE**, koji se razvijaju u saradnji istraživačkih centara iz **Italije** i **Slovenije**, nalaze se u fazi implementacije sveobuhvatnih platformi koje objedinjuju sve ključne komponente digitalnog vinogradarstva:

terenske senzore, analizu podataka pomoću veštačke inteligencije i **automatizaciju operacija kao što su navodnjavanje, primena zaštitnih sredstava i berba**. Njihov cilj je uspostavljanje zatvorenog sistema u kome se agronomske odluke donose i izvršavaju automatski, uz potpunu sledljivost i evidentiranje podataka u cloud okruženju (CORDIS, 2023).

Ovaj prelazak ka inteligentnoj automatizaciji predstavlja narednu fazu razvoja digitalnog vinograda. Omogućava smanjenje troškova i minimizaciju ljudskih grešaka, ali i **brže i preciznije reagovanje na promenljive uslove**, poput suša, naglih padavina ili pojave bolesti. Integracija ovih tehnologija dodatno unapređuje održivost proizvodnje i prilagođava vinogradarstvo klimatskim i tržišnim izazovima 21. veka.

4.6 Integrisane studije slučaja

Primena digitalnih tehnologija u vinogradima širom Evrope već daje konkretne rezultate koji potvrđuju vrednost integracije senzora, prediktivnih modela i automatizacije. U nastavku su predstavljena dva značajna primera **preciznog vinogradarstva** iz Iberijskog regiona: jedan na nivou parcele u **Ribera del Duero (Španija)**, i drugi na regionalnom nivou u dolini **Douro (Portugal)**.

Studija slučaja 1: Tehnološki unapređen vinograd u Ribera del Duero (Španija)

U vinogradu visoke kategorije u regionu Ribera del Duero implementiran je sveobuhvatan sistem pametnog monitoringa i upravljanja tokom tri uzastopne proizvodne sezone. Sistem je obuhvatao:

1. **Senzori u zemljištu i lokalne meteorološke stanice**, instalirani za kontinuirano praćenje podataka o vlažnosti, temperaturi, električnoj provodljivosti i padavinama, sa očitavanjem na svakih 15 minuta.
2. **Nedeljni snimci dobijeni dronovima (UAV)** opremljenim multispektralnim kamerama, koji omogućavaju izračunavanje vegetacionih indeksa kao što su NDVI i SAVI u visokoj rezoluciji (2,5 cm/piksel).
3. **Primena LSTM (Long Short-Term Memory) neuronskih mreža**, treniranih na istorijskim podacima o klimi, fenologiji i prethodnim berbama, sa sposobnošću predviđanja prinosa i pojave bolesti.
4. **Izrada mapa preporuka** za prilagođavanje navodnjavanja i fitosanitarnih tretmana u skladu sa specifičnim zonama upravljanja (EMZ).
5. **Automatizacija navodnjavanja** korišćenjem ventila povezanih sa sistemom za podršku odlučivanju (DSS), kao i VRT prskalice koje omogućavaju prilagođavanje doza u realnom vremenu.

6. **Integrirani mobilni dashboard** za upravljanje, u kojem se beleže sve sprovedene aktivnosti, uz potpunu sledljivost podataka (datum, doza, GPS lokacija i operater).

The quantified results after two years of use showed significant improvements:

- **Smanjenje potrošnje vode za 30%**, zahvaljujući planiranju navodnjavanja na osnovu vodnog stresa i fenološkog stadijuma biljke.
- **Smanjenje upotrebe fungicida za 25%**, kroz selektivne primene zasnovane na prediktivnim modelima.
- **Povećanje ujednačenosti prinosa vinograda**, sa prosečnim poboljšanjem od **+12% (kg/ha)**, posebno na zemljištima sa slabijim kapacitetom zadržavanja vode.
- **Priznanja na regionalnim takmičenjima kvaliteta**, gde su proizvedena vina ostvarila više ocene u senzornim analizama i tehničkim evaluacijama.

Ovaj primer jasno pokazuje potencijal potpuno integrisanog digitalnog vinogradarstva, u kojem se agronomske aktivnosti prilagođavaju u realnom vremenu na osnovu fizioloških, klimatskih i prostornih podataka (González-Fernández et al., 2022; Matese & Di Gennaro, 2021).



Slika 21. Upotreba dronova u vinarijama regiona Ribera del Duero. Izvor: Computing

Studija slučaja 2: Regionalni model predviđanja u Douro (Portugal)

Na širem, regionalnom nivou, Institut: “**Instituto Nacional de Investigação Agrária e Veterinária (INIAV)**” razvio je model za predviđanje prinosa grožđa u regionu **Alto Douro**, koristeći satelitske snimke i metode dubokog učenja. Sistem pod nazivom **InfoSolo** obuhvata sledeće komponente:

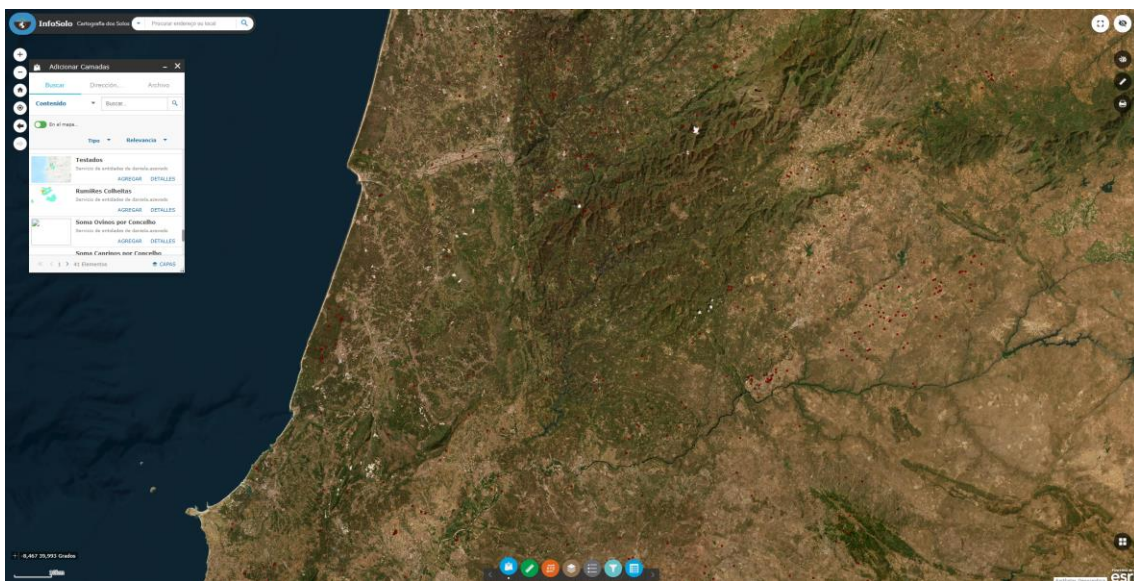
- Višetemporalne **Sentinel-2** satelitske snimke sa izračunatim vegetacionim indeksima (NDVI), prikupljenim tokom faza cvetanja i šarka.

- Istorijske i realne meteorološke podatke, uključujući prosečnu temperaturu, sunčevo zračenje i akumulaciju temperaturnih suma (degree-days).

- Modele trenirane pomoću LSTM neuronskih mreža, sposobnih da prepoznaju složene i nelinearne vremenske obrasce.

Rezultati su pokazali **srednju apsolutnu grešku (MAE) od 672 kg/ha**, što odgovara **relativnom odstupanju od 17%**. Kada su predviđanja vršena u fazi šarka, preciznost se dodatno poboljšala, sa greškom **manjom od ±8%**, što je dovoljno za operativne potrebe kao što su planiranje berbe i regionalno makroekonomsko upravljanje (Fernandes et al., 2022).

Ovi modeli su testirani u više vinogradarskih opština i pokazali su visok stepen skalabilnosti, omogućavajući izradu **mapa očekivanog prinosa** na regionalnom nivou. Na taj način olakšano je **planiranje transporta, organizacija skladišnih kapaciteta, pravovremeno zaključivanje prodajnih ugovora**, kao i procena i validacija poljoprivrednog osiguranja.



Slika 22. InfoSolo sistem mapiranja.

Source: InfoSolo

4.7 Prednosti i izazovi u praksi

Usvajanje digitalnih tehnologija i sistema za podršku odlučivanju u vinskom sektoru radikalno transformiše procese proizvodnje, upravljanja i plasmana vina. Implementacija senzora, prediktivnih modela, integrisanih platformi i automatizacije omogućava ne samo unapređenje operativne efikasnosti, već i uvođenje nove radne kulture zasnovane na objektivnim podacima i informisanom donošenju odluka.

Neposredne i proverljive prednosti:

1. **Donošenje odluka zasnovano na stvarnim podacima:** Jedna od najkonkretnijih prednosti digitalnog vinograda jeste **postepeno napuštanje subjektivne intuicije** i nesistematičnog iskustva, u korist **odlučivanja zasnovanog na empirijskim, izmerenim i analiziranim podacima**. Ovo omogućava preciznije, doslednije i sledljive agronomske intervencije, čime se unapređuju upravljanje i rezultati svake proizvodne sezone (Matese & Di Gennaro, 2021; Bramley, 2009).
2. **Značajno smanjenje upotrebe resursa:** Brojna istraživanja pokazuju da primena tehnologija precizne poljoprivrede omogućava smanjenje upotrebe inputa (vode, đubriva i fitosanitarnih sredstava) u **rasponu od 20% do 40%**, u zavisnosti od nivoa tehnološke integracije. Ova efikasnost ne samo da smanjuje troškove, već i **ublažava negativne uticaje na životnu sredinu**, poput difuznog zagađenja i prekomerne eksploatacije prirodnih resursa (Vendrell et al., 2020).
3. **Povećanje kvaliteta ploda i održivosti:** Mogućnost lokalizovanih intervencija, u skladu sa potrebama svake zone vinograda, doprinosi **optimizaciji vegetativno-reproduktivnog balansa vinove loze**, poboljšanju kvaliteta grožđa (veći sadržaj šećera, antocijana i uravnotežena kiselost) i **unapređenju održivosti proizvodnje** u uslovima klimatskih promena (González-Fernández et al., 2022).
4. **Sposobnost logističkog i komercijalnog planiranja unapred:** Prediktivni modeli prinosa i zrelosti omogućavaju **pravovremeno planiranje berbe**, bolje upravljanje radnom snagom i ranije zaključivanje komercijalnih ugovora. Takođe olakšavaju organizaciju procesa u vinariji (prijem, fermentacija, prerada) i **pregovore prodaje** zasnovane na verifikovanim podacima, a ne na procenama (Fernandes et al., 2022).

Preostali tehnički i organizacioni izazovi:

1. **Efikasna integracija hardvera, softvera i mehanizacije:** Uprkos tehnološkom napretku, jedan od glavnih izazova ostaje **interoperabilnost između uređaja i platformi**. Senzori različitih proizvođača, softver za analizu, VRT mehanizacija i sistemi upravljanja moraju biti pravilno povezani kako bi tok podataka bio kontinuiran i

pouzdan (Matese et al., 2022). Nedostatak univerzalnih standarda u poljoprivredi dodatno otežava ovaj proces.

2. **Kapacitet obrade i skladištenja podataka u realnom vremenu: Količina podataka koju generišu digitalni vinogradi je značajna, što zahteva infrastrukturu za obradu podataka u cloud-u, edge computing sisteme i mreže niske latencije.** Za donošenje odluka u realnom vremenu, poput reakcije na mraz ili preporuke za navodnjavanje, sistem mora imati visoku dostupnost i minimalno kašnjenje (CropX, 2023).
3. **Razvoj intuitivnih i korisnički prilagođenih interfejsa: Kontrolni paneli i vizualizacije često su razvijeni bez dovoljno agronomskog konteksta, što otežava njihovu upotrebu na terenu. Zbog toga je neophodna saradnja između krajnjih korisnika i dizajnera, zasnovana na principima upotrebljivosti i dizajna usmerenog na korisnika.** U projektima poput vite.net® pokazano je da kvalitetno dizajnirani interfejsi mogu smanjiti vreme potrebno za interpretaciju podataka i do 40% (CORDIS, 2021).
4. **Kontinuirana obuka zaposlenih i kalibracija sistema: Tehnologija sama po sebi ne transformiše upravljanje vinogradom. Neophodna je stalna edukacija kako bi se podaci pravilno tumačili, mape preporuka razumeli, senzori kalibrisali i parametri prilagodili.** Takođe, senzori zahtevaju redovnu kalibraciju kako bi se održala tačnost merenja, naročito u uslovima promenljivih klimatskih faktora (Bongiovanni & Lowenberg-DeBoer, 2004).

5. Sistemi za podršku odlučivanju (DSS) u preciznom vinogradarstvu

U eri digitalne transformacije poljoprivrede, **sistemi za podršku odlučivanju (DSS)** postali su operativno jezgro preciznog vinogradarstva. Njihova funkcija je da integrišu, obrade i analiziraju kompleksne informacije iz vinograda, generišući **objektivne, pravovremene i prilagođene agronomske preporuke**. Ovi sistemi predstavljaju kognitivnu strukturu koja omogućava da **se podaci pretvore u znanje**, a znanje u konkretnu akciju, u cilju efikasnije, održivije i otpornije proizvodnje vina (Gómez-Candón et al., 2020; Matese & Di Gennaro, 2021).

5.1 Šta je DSS i koja je njegova svrha?

DSS se može definisati kao **tehnološka platforma koja kombinuje prediktivne modele, agronomske algoritme i podatke u realnom vremenu** kako bi generisala praktične i automatizovane instrukcije za rad na terenu. Na primer, DSS sistem u jednoj vinariji može na početku dana prikupiti podatke o vlažnosti zemljišta, temperaturi vazduha, vremenskoj prognozi, satelitskim ili dron snimcima, kao i planu rada terenskog tima. Na osnovu tih informacija, sistem primenjuje fenološke modele, pragove vodnog stresa, modele za predviđanje bolesti i unapred definisane agronomske strategije, kako bi generisao konkretne preporuke, kao što su:

- „Primeni 8 mm navodnjavanja u zoni upravljanja (ZME) 3.“
- „Srednji rizik od plamenjače na parcelama sa severnom ekspozicijom.“
- „Proveriti fenološku zrelost u redovima 12–16 u jutarnjim satima.“

Ova sposobnost sinteze i izvršenja u realnom vremenu čini DSS **digitalnim agronomskim asistentom**, koji može raditi sa nivoom preciznosti i brzine nedostižnim za manuelni rad ili tradicionalno oslanjanje na iskustvo (Bongiovanni & Lowenberg-DeBoer, 2004; Finger et al., 2019).

Međutim, uloga DSS sistema ne završava se na operativnim preporukama. Ovi sistemi funkcionišu i kao **baze istorijskih podataka**, u kojima se beleži svaka sprovedena intervencija, uključujući datum, količinu, korišćenu mehanizaciju i odgovornog operatera. Ovakva evidencija omogućava sprovođenje **komparativnih analiza između različitih sezona, sorti ili parcela**. Zahvaljujući akumulaciji podataka i primeni principa mašinskog učenja, DSS sistemi se vremenom unapređuju – prilagođavaju pragove odlučivanja, rekalibrišu modele i dodatno personalizuju preporuke na osnovu specifičnosti vinograda i prethodnih rezultata (Pérez-Delgado et al., 2023).

Krajnji cilj ovih sistema jeste prelazak sa **reaktivnog vinogradarstva** - koje reaguje na probleme nakon što se pojave - ka proaktivnom i **prediktivnom pristupu**, koji omogućava **pravovremeno planiranje, anticipaciju rizika i optimizaciju resursa**. U tom kontekstu, DSS sistemi predstavljaju most između precizne poljoprivrede i savremenih koncepata **pametne poljoprivrede** i

vinogradarstva 5.0, gde se spajaju održivost, efikasnost i digitalizacija (Zarco-Tejada et al., 2014; Finger et al., 2019).

Primeri primene DSS sistema u vinogradarstvu uključuju platforme kao što su **Vite.net**®, razvijen od strane kompanije Horta srl u Italiji, kao i **SmartVitis**, projekat Univerziteta u Firenci, koji je testiran u vinogradima u Toskani, La Rioji i Burgundiji. Ova rešenja integrišu klimatske senzore, multispektralne snimke, fenološke modele i mape preporuka, omogućavajući izuzetno precizno upravljanje svim fazama proizvodnog ciklusa vina.



Slika 23. DSS Vite.net indikatori rizika. Izvor: Vite.net

5.2 Tehnička arhitektura DSS sistema u vinogradarstvu

Sistem za podršku odlučivanju (DSS) u digitalnom vinogradarstvu organizuje transformaciju podataka u operativne akcije kroz jasno definisan i

strukturiran proces. Ovaj tok može se podeliti na šest ključnih faza, od kojih svaka ima specifičnu ulogu u agronomskom upravljanju:

1. Multisenzorsko prikupljanje podataka

Prvi korak podrazumeva prikupljanje informacija iz različitih fizičkih izvora:

- **Senzori u zemljištu:** kapacitivni, tensiometarski ili FDR senzori za merenje vlažnosti i električne provodljivosti (Ojha et al., 2015).
- **Dodatni in-situ senzori:** npr. senzori turgorskog pritiska lista (LeafSen), senzori protoka biljnog soka ili pH senzori, koji prate fiziološko stanje biljke (LeafSensor, 2023; Steppe et al., 2008).
- **Meteorološke stanice:** za praćenje temperature, vlažnosti, vetra, zračenja i padavina (Jones et al., 2010).
- **Daljinska osmatranja:** satelitski snimci (Sentinel-2), multispektralni dronovi i termalne kamere, koji omogućavaju izračunavanje indeksa poput NDVI ili CWSI (Delegido et al., 2011; Matese & Di Gennaro, 2015).
- **Ručno uneti podaci:** kao što su datumi rezidbe, sorte, vrste tretmana, gustina sadnje i drugi agronomski parametri.

Kombinacija ovih izvora stvara bogat i heterogen skup podataka koji predstavlja osnovu sistema upravljanja.

2. Predobrada podataka

Pre analize, podaci moraju proći proces obrade:

- **Detekcija i korekcija anomalnih vrednosti.**
- **Periodična kalibracija senzora** radi eliminacije odstupanja (drift) (Ammoniaci et al., 2021).
- **Prostorna i vremenska interpolacija** radi ujednačavanja rezolucije podataka.
- **Konverzija jedinica** u standardizovane operativne vrednosti (mm, °C i dr.).

Ova faza obezbeđuje konzistentnost, uporedivost i pouzdanost podataka za dalju obradu.

3. Računski (analitički) sloj

Algoritmi obrađuju pripremljene podatke koristeći različite pristupe:

- **Agronomska pravila,** kao što su stepen-dani (GDD) i fenološki modeli zasnovani na BBCH skali (Brisson et al., 2003).
- **Fitosanitarni modeli upozorenja,** poput Gubler-Thomas indeksa ili EPI modela za botritis i plamenjaču (Gubler et al., 1999).
- **Prediktivni modeli zasnovani na veštačkoj inteligenciji (ML i DL),** za procenu vodnog stresa, pojave bolesti i prinosa (Fernandes et al., 2022; Kerkech et al., 2020).

- **Generisanje mapa preporuka** za navodnjavanje i tretmane varijabilne doze (VRT) u skladu sa specifičnim zonama (Ammoniaci et al., 2021).

Ovaj sloj generiše hijerarhijski strukturisane informacije, od dijagnoze do konkretnih preporuka.

5. Izvršni sloj (Action Engine)

Rezultati analize pretvaraju se u konkretne akcije:

- **Izvoz VRT mapa** ka poljoprivrednoj mehanizaciji (traktori, prskalice, sistemi za fertirigaciju) (Ammoniaci et al., 2021).
- **Automatska obaveštenja** putem mobilnih aplikacija, e-maila ili web platformi, sa preciznim instrukcijama za rad na terenu.
- **Automatizovano upravljanje sistemima**, poput aktivacije ventila za navodnjavanje ili sistema za zaštitu bilja putem digitalnih signala.

Na ovaj način DSS prelazi iz konsultativnog u **delimično autonomni izvršni sistem**.

5. Korisnički interfejs (UX/HMI)

Efikasna interakcija sa sistemom zahteva jasno i intuitivno okruženje:

- **Vizuelizacije podataka kroz interaktivne mape i vremenske grafikone** (NDVI, vlažnost, vodni stres itd.) (Ammoniaci et al., 2021).
- **Kategorizovana upozorenja** („hitno“, „proveriti“, „standardno“) radi lakšeg prioritizovanja aktivnosti.
- **Geolocirana evidencija svih aktivnosti** (navodnjavanje, tretmani, berba), uz potpunu sledljivost i pristup istorijskim podacima.

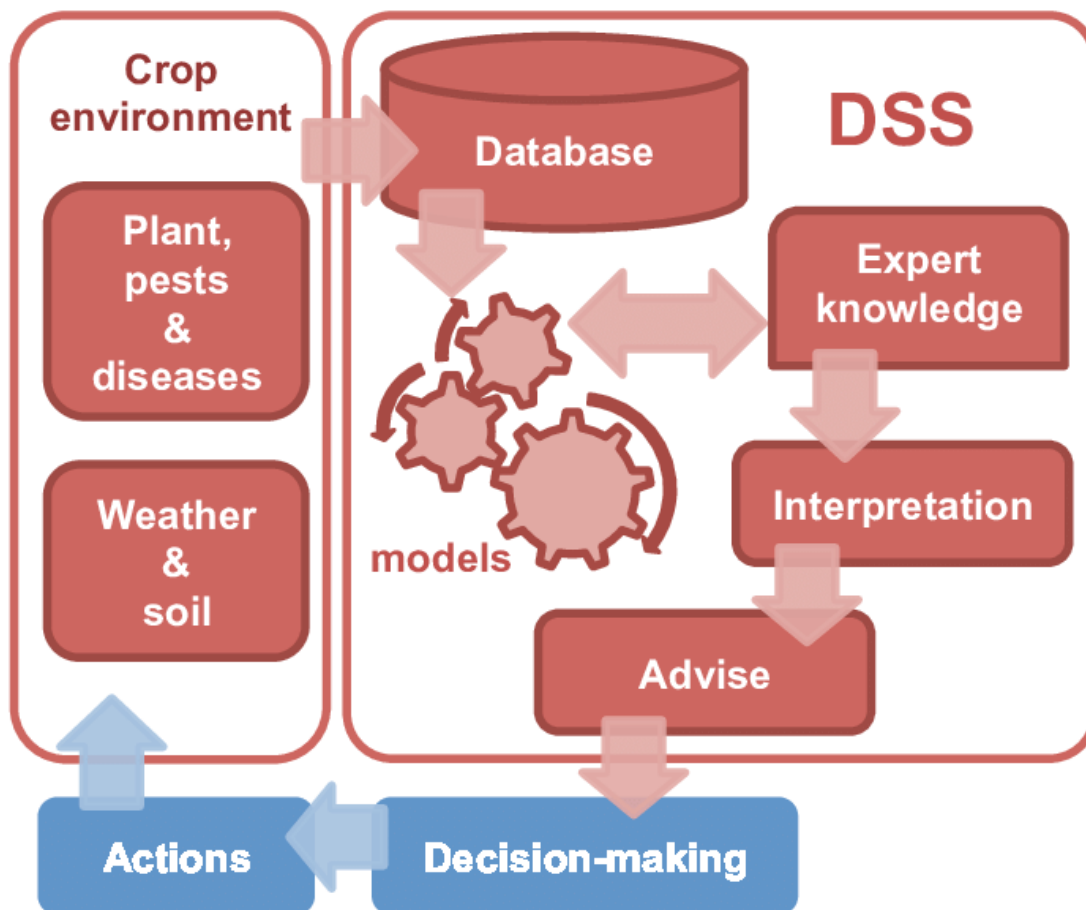
Kvalitetan korisnički interfejs ključan je za prihvatanje i praktičnu primenu DSS sistema.

6. Dinamički efekat i kontinuirano učenje

DSS funkcioniše kroz stalni **ciklus povratne informacije**:

- Analiza rezultata sprovedenih akcija (npr. efekat tretmana ili stanje vlage nakon navodnjavanja).
- Prilagođavanje pragova i modela na osnovu postignute efikasnosti.
- Kontinuirano proširivanje baze podataka i unapređenje algoritama kroz mašinsko učenje (Pérez-Delgado et al., 2023).

Ovaj proces omogućava DSS sistemu da ne samo izvršava zadatke, već i da **uči i evoluira kroz vreme**.



Slika 24. Primer DSS sistema za tretman bolesti u usevu. : Vittorio et al. 2012

5.3 Modeli i algoritmi koji se koriste u DSS sistemima

Fenološko modeliranje i analiza zrelosti

Fenološko modeliranje kombinuje više izvora informacija – akumuliranu temperaturu (GDD), tradicionalne datume kretanja pupoljaka i sazrevanja, kao i satelitske podatke - kako bi definisalo fleksibilan vremenski **okvir berbe** od 5 do 7 dana, umesto fiksnog datuma. Ovakav pristup omogućava bolje prilagođavanje berbe klimatskim uslovima konkretne godine i unapređuje donošenje odluka u vezi sa optimalnim trenutkom berbe (Chuine et al., 2013; Basile et al., 2023).

Modeliranje fitosanitarnih rizika

Tradicionalni modeli, kao što su **Gubler-Thomas** i **Epidemiološki indeks rizika (EPI)**, unapređeni su integracijom veštačke inteligencije. Novi sistemi uključuju parametre poput temperature, vlažnosti, evapotranspiracije i mikroklimatskih uslova po zonama upravljanja (ZME), generišući **automatska upozorenja** koja omogućavaju smanjenje nepotrebne primene fungicida. U pojedinim slučajevima, njihova primena dovela je do smanjenja upotrebe

sredstava za zaštitu bilja i do **32%**, bez narušavanja zdravstvene zaštite vinograda (Gubler et al., 1999; Ayaz et al., 2019).

Modeliranje vodnog stresa

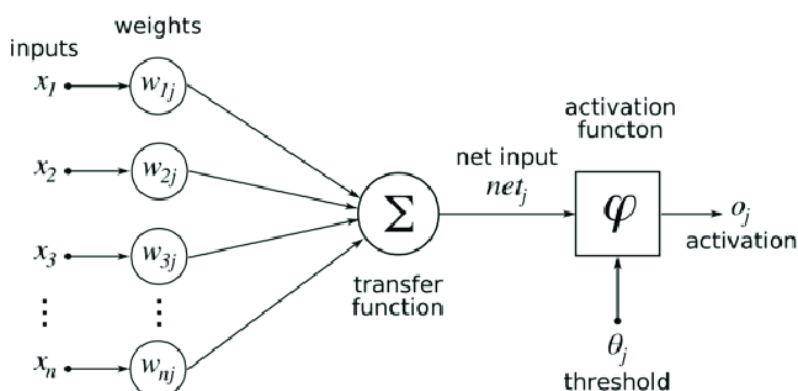
Modeliranje vodnog balansa vinograda, u kombinaciji sa senzorima vlažnosti zemljišta i senzorima pritiska lista, omogućava pravovremeno prepoznavanje deficita vode i aktivaciju navodnjavanja pre nego što biljka uđe u stres. Ovakav pristup omogućava smanjenje potrošnje vode za **15-20%**, uz preciznije i ciljano upravljanje resursima (LeafSensor, 2023; Steppe et al., 2008).

Predviđanje prinosa

Podaci sa senzora, meteorološki podaci, istorijske serije i snimci dronova integrišu se u modele kao što su **Random Forest** ili **LSTM**. U regionu Rioja Alavesa, LSTM model postigao je **tačnost od 87%** u proceni prinosa (kg/ha), koristeći podatke iz više proizvodnih sezona (Fernandes et al., 2022).

Automatska detekcija štetočina i bolesti

Primena **konvolucionih neuronskih mreža (CNN)** na multispektralne snimke omogućava identifikaciju simptoma bolesti poput pega na listovima, plamenjače, pepelnice ili botritisa sa **pouzdanošću većom od 90%**. Ovi sistemi omogućavaju automatsko aktiviranje pragova za intervenciju, čime se povećava efikasnost zaštite i smanjuje nepotrebna primena sredstava (Kerkech et al., 2020; Ayaz et al., 2019).



Slika 25. Šematski prikaz veštačkog neurona. Izvor: Ūnal, Z. 2020.

5.4 Realna iskustva i rezultati sa terena

Razvoj i primena sistema za podršku odlučivanju (DSS) revolucionisali su upravljanje vinogradima, omogućavajući integraciju prikupljanja podataka, prediktivne analize i vizualizacionih tehnologija u konkretne agronomske akcije. U nastavku su prikazani neki od najznačajnijih projekata i platformi koji ilustruju njihov praktični potencijal:

VINTAGE projekat

Ovaj evropski projekat, implementiran u ključnim vinogradarskim regionima kao što su **La Rioja (Španija), Toskana (Italija) i Burgundija (Francuska)**, pokazao je izuzetne rezultate u pogledu efikasnosti. Sistem je integrisao module za pametno navodnjavanje, praćenje zdravstvenog stanja biljaka i diferenciranu berbu, uz smanjenje upotrebe inputa **između 20 i 30%** zahvaljujući tehnikama segmentirane berbe, pravovremenim tretmanima i upotrebi senzora u realnom vremenu (CORDIS, 2022).

Jedan od ključnih elemenata bio je **dizajn korisničkog interfejsa**, koji je razvijen i testiran u saradnji sa lokalnim vinogradarima. Zahvaljujući tome, sistem je postigao visok nivo prihvaćenosti, što potvrđuje da je **jednostavnost korišćenja presudan faktor** za integraciju digitalnih rešenja na malim i srednjim gazdinstvima.




Slika 1. VINTAGE Projekat

VineSens

Modularni DSS sistem usmeren na porodične vinarije i male proizvođače, razvijen od strane španskog konzorcijuma. Ovaj sistem kombinuje senzore za **vlažnost, temperaturu, pritisak i druge parametre okruženja**, zajedno sa jednostavnim agronomskim pravilima, sve integrisano u web platformu jednostavnu za korišćenje.

U jednom primeru primene u La Rioji, **VineSens je omogućio smanjenje potrošnje vode za 18%**, bez ugrožavanja zdravstvenog stanja vinograda, čak i u nepovoljnim vremenskim uslovima (VineSens, 2020). Sistem pokazuje da je i sa ograničenim resursima moguće efikasno i ekonomično primeniti principe preciznog vinogradarstva.



Slika 27. Integracija senzora u VineSens sistemu. Izvor: Dani Ortega

GrapeDSS

Skalabilna komercijalna platforma koja se koristi na više kontinenata, namenjena vinarijama svih veličina. Njeni moduli obuhvataju:

- **Modele uravnotežene ishrane**, prilagođene tipu zemljišta i sorti.
- **Izbor podloga** optimizovan prema lokalnim klimatskim i fitopatološkim uslovima.
- **Planiranje tretmana** na osnovu fitosanitarnih upozorenja, NDVI indeksa i meteoroloških podataka.

Njegov **dizajn prvenstveno prilagođen mobilnim uređajima** čini ga posebno korisnim u područjima gde postoji velika zavisnost od mobilnog pristupa i rada na daljinu. Takođe, omogućava direktan izvoz VRT mapa ka povezanoj mehanizaciji, čime se olakšava diferencirano agronomsko upravljanje.



Slika 2. GrapeDSS Projekat

AI-GRAPe Projekat

Transnacionalni projekat fokusiran na primenu veštačke inteligencije za **rano otkrivanje štetočina** i optimizovano agronomsko upravljanje. Zasniva se na kombinovanoj upotrebi **dronova, terenskih senzora i konvolucionih neuronskih mreža** za identifikaciju simptoma bolesti kao što su pepelnica, plamenjača ili botritis, i to pre nego što postanu vidljivi golim okom.

Trenutno u naprednoj fazi validacije, projekat ima za cilj da u periodu od 24 meseca ostvari **smanjenje upotrebe pesticida za 20% i povećanje prinosa za 15%** (CORDIS, 2023). Njegov fokus na održivost i smanjenje hemijskih intervencija pozicionira ga kao važan model za ekološku tranziciju vinogradarstva.

Slika 3. AI-GRAPE Projekt

WANUGRAPE 4.0

Španski razvoj fokusiran na **kreiranje modularnog i integrativnog DSS sistema**, sposobnog da funkcioniše u vinogradima sa različitim nivoima digitalizacije. Sistem se ističe po sledećim karakteristikama:

- Uključuje modele za **predviđanje vodnog i nutritivnog statusa**, čak i u odsustvu direktnih senzora.
- Koristi algoritme prilagođene **autohtonim sortama** i lokalnim uslovima.
- Uključuje logiku kontinuiranog učenja kroz analizu istorijskih podataka iz prethodnih proizvodnih sezona.

Ovaj DSS omogućava pouzdanu procenu vodnog i nutritivnog statusa na osnovu minimalnog skupa podataka, koristeći interpolaciju i empirijska pravila potvrđena u praksi, što ga čini posebno pogodnim za vinogradarstvo u ruralnim područjima sa slabije razvijenom tehnološkom infrastrukturom.



Slika 30. Presentacija rezultata projekta WANUGRAPE 4.0. Izvor: Inagea

5.5 Ključni faktori uspeha DSS sistema

Da bi **sistem za podršku odlučivanju (DSS)** zaista bio transformativan u vinogradarskom kontekstu, mora biti efikasno integrisan u agronomsku, društvenu i tehničku realnost gazdinstva. Ključni elementi koji određuju njegovu efikasnost prikazani su u nastavku:

1. Konzistentan kvalitet podataka

Performanse sistema direktno zavise od **pouzdanosti i konzistentnosti prikupljenih podataka**. To podrazumeva **redovnu kalibraciju senzora, fizičku proveru** očitavanja na terenu i implementaciju automatskih procedura za detekciju i uklanjanje odstupanja ili anomalija (Ammoniaci et al., 2021). Bez tačnih podataka, preporuke mogu biti neusaglašene sa stvarnim stanjem, što smanjuje poverenje korisnika.

2. Specifično teritorijalno modeliranje

Svako gazdinstvo ima **jedinstvene mikrosisteme**, definisane tipom zemljišta, sortama vinove loze, podlogama i lokalnim mikroklimatskim uslovima. Kako bi se postigla maksimalna preciznost, modeli treba da **budu prilagođeni konkretnom kontekstu**: kalibrisani na nivou zona upravljanja (ZME), usklađeni sa lokalnim fenološkim obrascima i prilagođeni sezonskim ciklusima (Matese & Di Gennaro, 2015).

3. Intuitivan i upotrebljiv interfejs

Stvarna primena DSS sistema u velikoj meri zavisi od **korisničkog iskustva (UX)**. Interfejs treba da omogući jasne kontrolne panele, interaktivne vizualizacije, pristup na daljinu putem mobilnih uređaja i ergonomiju razvijenu **kroz saradnju sa vinogradarima**. Projekti poput VINTAGE ili vite.net® pokazali su da poboljšanje upotrebljivosti **može smanjiti vreme interpretacije podataka i do 40%** (CORDIS, 2021).

4. Tehnološka kompatibilnost

Kvalitetan DSS mora biti **interoperabilan**, odnosno kompatibilan sa sensorima različitih proizvođača, omogućavati izvoz mapa u GIS/VRT formatima i podržavati standardne komunikacione protokole kao što su LoRaWAN ili NB-IoT, kako bi se obezbedila povezanost i u ruralnim područjima (Ojha et al., 2015).

5. Postepena ekonomska implementacija

Ne mogu sva gazdinstva odjednom investirati u visok nivo tehnologije. Zato sistemi treba da budu **modularni**, omogućavajući početak sa osnovnim komponentama niže cene (senzori, softverski alati), uz mogućnost postepenog proširenja (navodnjavanje, zaštita bilja, berba). Ova strategija uspešno je primenjena u sistemima kao što su VineSens, GrapeDSS ili WANUGRAPE 4.0.

6. Kontinuirana obuka

Uspeh DSS sistema zavisi od **ljudskog faktora**. Neophodno je obezbediti **stalnu i praktičnu edukaciju** kroz radionice, tehničku podršku i vizuelne materijale za interpretaciju mapa, krivih stresa ili fenoloških upozorenja. Time se obezbeđuje pravilna primena preporuka i podstiče prihvatanje tehnologije (Bramley, 2009).

7. Institucionalna podrška

Podrška javnih politika i sertifikacionih sistema deluje kao **značajan pokretač** primene DSS sistema. Nacionalne i evropske subvencije, ekološke sertifikacije i zahtevi za sledljivost podstiču ulaganja, jer omogućavaju povraćaj investicije, pristup tržištima više vrednosti i usklađenost sa ekološkim regulativama (Wolfert et al., 2017).

6. Izazovi i mogućnosti digitalizacije u vinogradarstvu

6.1 Technological and agronomic opportunities

Uvođenje digitalnih tehnologija u upravljanje vinogradima otvara širok spektar mogućnosti za optimizaciju proizvodnje, povećanje održivosti i unapređenje profitabilnosti. Ova rešenja omogućavaju preciznije intervencije, prilagođene stvarnim potrebama svake zone vinograda, zahvaljujući naprednom prikupljanju i obradi podataka.

Profitabilnost zasnovana na aerofotogrametriji (mapiranju iz vazduha)

Primena dronova opremljenih multispektralnim sensorima pokazala se kao izuzetno efikasna u identifikaciji zona različite bujnosti unutar iste parcele. U istraživanjima sprovedenim u vinogradima u Italiji, sistematska upotreba ovih tehnologija omogućila je rano otkrivanje fitosanitarnih problema i diferencirano upravljanje u skladu sa vegetativnim razvojem. To je rezultiralo povećanjem profitabilnosti i smanjenjem inputa kroz preciznije i lokalizovane intervencije (Serena Sofia et al., 2025).

Optimizacija upotrebe vode

Tehnologije daljinskog osmatranja, u kombinaciji sa sensorima vlažnosti zemljišta i biljaka, pokazale su se kao efikasan alat za unapređenje upravljanja navodnjavanjem. Omogućavaju prilagođavanje količine vode stvarnim potrebama vinograda, čime se izbegavaju i vodni stres i prekomerno navodnjavanje. Ovo pozitivno utiče na kvalitet grožđa i održivost proizvodnje (Wang et al., 2021). U više vinogradarskih regiona Mediterana, uključujući Kastilju-La Manču, Langdok i Siciliju, potvrđene su uštede vode bez smanjenja prinosa.

Digitalna sledljivost i dodatna vrednost

Jedna od najznačajnijih prednosti digitalizacije jeste mogućnost beleženja svih operacija u vinogradu, od sadnje do berbe i vinifikacije. Ovakva digitalna evidencija olakšava interno upravljanje, ali i omogućava dokazivanje usklađenosti sa ekološkim, zdravstvenim i kvalitetnim standardima. Potpuna sledljivost postaje važan marketinški alat, jer pruža transparentnost krajnjim potrošačima i olakšava dobijanje sertifikata poput organske proizvodnje, integrisane proizvodnje ili oznake geografskog porekla.

Sistemi koji omogućavaju digitalno praćenje agrotehničkih mera, meteoroloških uslova i primenjenih tretmana doprinose jačanju imidža održivosti vinarije. U kontekstu sve zahtevnijih potrošača koji obraćaju pažnju na poreklo i ekološki uticaj proizvoda, ovaj aspekt predstavlja značajnu konkurentsku prednost.

6.2 Tehnološki i operativni izazovi

Iako digitalna tranzicija u vinogradarstvu donosi brojne mogućnosti, ona istovremeno postavlja značajne tehničke, ekonomske i društvene izazove koje je potrebno prevazići kako bi se omogućila njena šira primena. U nastavku su prikazane glavne prepreke u digitalizaciji vinograda.

Visoki početni i troškovi održavanja

Usvajanje naprednih tehnologija, kao što su senzori vlažnosti, povezane meteorološke stanice, dronovi sa multispektralnim kamerama, platforme za upravljanje poljoprivrednim podacima (FMIS) i mehanizacija za varijabilnu primenu, zahteva značajna početna ulaganja. Istraživanja sprovedena u okviru projekta RDI Precision u Bordou (Boraud et al., 2022) pokazuju da ukupni troškovi kompletnog sistema preciznog vinogradarstva mogu lako premašiti 100.000 €, ne uključujući dodatne troškove obuke, održavanja, licenci za softver ili pretplata na digitalne platforme. Ova finansijska barijera ograničava pristup tehnologiji pre svega na velika gazdinstva i zadruge, dok se mala i srednja gazdinstva često oslanjaju na modele deljenja resursa ili usluge po zahtevu (SaaS).

Ograničena interoperabilnost sistema

Jedan od najvećih izazova u digitalnom agrarnom ekosistemu jeste interoperabilnost između različitih uređaja i platformi. Terenski senzori često koriste različite komunikacione protokole (LoRaWAN, NB-IoT, Zigbee), dok traktori i mehanizacija funkcionišu kroz zatvorene ili vlasničke sisteme. Ovakva neusklađenost otežava integraciju, povećava troškove i stvara zavisnost od jednog dobavljača, čime se smanjuje fleksibilnost sistema (Wolfert et al., 2017). Zbog toga je uspostavljanje otvorenih standarda i interoperabilnih rešenja ključno za dalji razvoj digitalizacije.

Upravljanje velikim količinama podataka (Big Data)

Intenzivna digitalizacija vinograda podrazumeva svakodnevno generisanje velikih količina podataka iz različitih izvora - senzora, satelita, dronova, meteoroloških stanica i upravljačkih platformi. Ukoliko se ovi podaci ne upravljaju adekvatno, mogu predstavljati problem umesto koristi. Izazov je obezbediti sigurno skladištenje u cloud-u, podršku za API integracije, filtriranje relevantnih informacija i njihovu vizualizaciju u realnom vremenu na način razumljiv korisnicima na terenu. To zahteva ne samo odgovarajuću IT infrastrukturu, već i stručnjake sa znanjem iz oblasti data science-a (Kamilaris et al., 2017).

Lokalna kalibracija i sezonska prilagođavanja

Za tačan rad senzora i prediktivnih modela neophodna je precizna kalibracija za svaku parcelu, sortu i mikroklimatske uslove. Na primer, model za predviđanje plamenjače razvijen u Bordou neće nužno davati pouzdane rezultate

u regionu Priorat bez prilagođavanja lokalnim uslovima. Ovaj proces zahteva kontinuirano prikupljanje uzoraka sa terena, agronomske analize, podešavanje parametara i kontrolu kvaliteta podataka tokom svake proizvodne sezone (Tisseyre et al., 2018).

Problemi sa povezanošću u ruralnim područjima

Nedostatak telekomunikacione infrastrukture u mnogim ruralnim regionima predstavlja ozbiljnu prepreku za primenu digitalnih rešenja. U pojedinim vinogradarskim područjima Španije, Portugala, istočne Evrope, kao i u zemljama u razvoju, i dalje postoje ograničenja u pristupu mobilnim mrežama i brzom internetu. To otežava korišćenje cloud servisa i integraciju IoT uređaja u realnom vremenu, pa se često pribegava lokalnim rešenjima kao što su LoRaWAN mreže ili offline sistemi za skladištenje podataka (Verdouw et al., 2021).

Privatnost, upravljanje i vlasništvo nad podacima

Digitalizacijom vinograda značajno raste količina generisanih podataka, što otvara važna etička i pravna pitanja u vezi sa njihovim upravljanjem i vlasništvom. Mnogi proizvođači izražavaju zabrinutost zbog mogućnosti neovlašćenog korišćenja podataka od strane tehnoloških kompanija ili platformi. Evropska unija je prepoznala ovaj problem i kroz Evropsku strategiju podataka jasno definisala da podaci generisani na gazdinstvu pripadaju proizvođaču, uz obavezu poštovanja Opšte uredbe o zaštiti podataka (GDPR) i razvoj specifičnih regulativa za agro-prehrambeni sektor (European Commission, 2020).

6.3 Ljudski i kulturni izazovi

Prelazak na digitalno vinogradarstvo ne podrazumeva samo uvođenje naprednih tehnologija, već i duboku promenu načina razmišljanja, organizacione kulture i društvenih odnosa u poljoprivrednom okruženju. Ljudski i kulturni izazovi često su složeniji i dugotrajniji od tehničkih, jer se odnose na vrednosti, uverenja i navike koje su se razvijale kroz generacije rada u vinogradu. U nastavku su predstavljene glavne prepreke u ovoj dimenziji digitalne transformacije.

1. Otpor prema promenama

Otpor prema usvajanju novih tehnologija jedan je od ključnih faktora koji ograničava širenje preciznog vinogradarstva. U tradicionalnim vinogradarskim regionima, kao što su La Rioja (Španija), dolina Loare (Francuska) ili Burgundija, gde su iskustvo i direktno posmatranje vinograda istorijski bili osnova agronomskog znanja, mnogi vinogradari digitalne alate doživljavaju kao nepotrebne, previše složene ili čak kao pretnju njihovoj profesionalnoj autonomiji. Istraživanja koja su sprovedli DataIntel (2023) i Univerzitet u Monpeljeu pokazuju da više od 45% vinogradara starijih od 55 godina smatra da digitalizacija

smanjuje njihovu kontrolu nad proizvodnjom i otežava donošenje odluka koje su se ranije donosile „od oka“ ili na osnovu iskustva.

2. Nedostatak digitalnih veština

Efikasna upotreba senzora, GIS platformi, dashboard-a, dronova i prediktivnih modela zahteva skup veština koje tradicionalno nisu deo znanja vinogradara. Pojmovi kao što su NDVI, evapotranspiracija, regresija ili mašinsko učenje zahtevaju osnovno razumevanje statistike, informatike i upravljanja podacima. Evropska komisija navodi da više od 60% radnika u ruralnim područjima nema osnovne digitalne veštine (European Commission, 2020). Zbog toga gazdinstva moraju angažovati nove stručnjake ili dodatno obučavati postojeće radnike, što zahteva dodatna ulaganja u vreme i resurse. Kao efikasna rešenja pokazale su se lokalne zadruge i udruženja koja organizuju zajedničke obuke ili dele troškove angažovanja stručnjaka.

3. Transformacija organizacije rada

Digitalizacija značajno menja način organizacije rada u vinogradu. Tradicionalni kalendarski pristup više nije dovoljan, već je potrebno usklađivati aktivnosti sa digitalnim upozorenjima, donositi odluke na osnovu mapa preporuka, beležiti sve intervencije putem mobilnih platformi i prilagođavati praksu specifičnostima unutar parcela. Ova promena zahteva redefinisane radnih procesa, novu raspodelu zadataka unutar tima i fleksibilnije planiranje zasnovano na podacima. Prema istraživanjima Univerziteta u Padovi (Zambon et al., 2019), ovakva transformacija zahteva snažno agronomsko vođstvo, participativno planiranje i aktivno uključivanje tehničkog osoblja u sve faze digitalizacije.

4. Potreba za međuinstitucionalnom saradnjom

Digitalna transformacija ne može se sprovesti izolovano. Praksa pokazuje da je njena primena najuspešnija u okviru saradničkih modela, kao što su zadruge, organizacije za zaštitu geografskog porekla, poljoprivredna udruženja ili tehnološki klasteri. Ove mreže omogućavaju razmenu znanja, tehnologija i resursa, smanjuju troškove i ubrzavaju proces učenja. Kolektivni projekti, poput onih razvijenih u okviru SmartAgriHubs ili klastera Vitinnova u Španiji, pokazali su da saradnja olakšava pristup novim tehnologijama, povećava poverenje među akterima i podstiče razvoj inovacione kulture (Wolfert et al., 2017).

U tom kontekstu, od presudnog značaja je i postojanje efikasnog lokalnog upravljanja koje koordinira saradnju, obezbeđuje ravnopravan pristup resursima i organizuje obuke prilagođene stvarnim potrebama vinogradara.

6.4 Ekonomski aspekti i modeli usvajanja

Implementacija digitalnih tehnologija u vinogradarstvu ima značajne finansijske i strateške implikacije. U nastavku su prikazani ključni faktori koji utiču na njihovu efikasnu primenu:

Uticaj na povraćaj investicije (ROI)

Istraživanja agroekonomista pokazuju da se ulaganja u digitalne tehnologije isplate u periodu **od 3 do 5 godina**, naročito na gazdinstvima većim od 20 ha ili u zadrugama koje koriste prednosti ekonomije obima. Ovaj povraćaj ostvaruje se kroz smanjenje potrošnje vode (20–30%) i hemijskih inputa, kao i kroz pristup premium tržištima zahvaljujući diferencijaciji proizvoda i unapređenju percepcije kvaliteta (Serena Sofia et al., 2025; Farmonaut, 2024; Tey & Brindal, 2012).

SaaS i modeli upravljanih usluga

Poljoprivredne platforme se sve češće nude kroz **SaaS (Software as a Service) model**, koji obuhvata senzore, digitalnu platformu i tehničku podršku u okviru godišnje pretplate. Ovakav pristup eliminiše potrebu za velikim početnim ulaganjima, prilagođava troškove broju hektara ili senzorskih tačaka i omogućava postepeno usvajanje tehnologije (Saiwa, 2023; Wikipedia, 2024).

Subvencije i sertifikacije

Poljoprivredni podsticaji, kao što su sredstva iz Programa ruralnog razvoja (RDP), evropski i nacionalni fondovi, kao i sertifikati organske ili integrisane proizvodnje, predstavljaju značajan finansijski podsticaj. Deo troškova digitalizacije može biti pokriven kroz ove mehanizme, što podstiče vinarije da učestvuju u zajedničkim inicijativama i ostvaruju dodatne benefite kroz reputaciju i pristup specijalizovanim tržištima

Progresivna implementacija tehnologije

Efikasan pristup uvođenju digitalnih rešenja podrazumeva **faznu implementaciju**:

- **Faza 1: Instalacija meteorološke stanice i senzora u zemljištu.**
- **Faza 2: Uvođenje dronova za aerofotogrametriju i mapiranje.**
- **Faza 3: Primena VRT mehanizacije i automatizovanih sistema za navodnjavanje.**

Ovakav pristup omogućava evaluaciju rezultata u svakoj fazi, prilagođavanje budžeta u skladu sa ostvarenim efektima i smanjenje finansijskog rizika, uz postepeno skaliranje investicije (Kent Downs, 2021).

6.5 Trendovi u usponu

Identifikovano je pet ključnih trendova u tehnološkom i agronomskom razvoju digitalnih vinograda, sa značajnim potencijalom za integraciju u sisteme upravljanja vinogradima.

1. Robotizacija specifičnih operacija

Razvoj autonomnih robota za specifične zadatke, kao što je rezidba, napreduje velikom brzinom. Robotske platforme poput **Bumblebee** – namenjene rezidbi pojedinačnih čokota – i **HyQReal** – četvoronožni robot – pokazale su tehničku izvodljivost, uz preciznost od **87%** i trajanje rezidbe od **213 sekundi po čokotu**. Ovi rezultati zasnovani su na istraživanjima objavljenim na platformama kao što su arXiv i ResearchGate. Globalno tržište robotizacije u vinogradarstvu iznosilo je **234 miliona USD u 2024. godini**, sa projekcijom rasta na **690 miliona USD do 2033. godine**, uz prosečnu godišnju stopu rasta (CAGR) od 13% (DataIntel, 2024).

2. Objasnjiva i integrisana veštačka inteligencija

Koncept **objasnjive veštačke inteligencije (XAI)** sve više dobija na značaju, posebno u platformama poput **AI-GRAPE**, gde modeli ne samo da generišu upozorenja na pojavu štetočina i bolesti nekoliko dana unapred, već omogućavaju i ljudsku verifikaciju tih upozorenja pre primene tretmana. Ovakav hibridni pristup pokazao je smanjenje upotrebe pesticida za oko **20%**, zahvaljujući eliminaciji lažnih alarma i optimizaciji intervencija (CORDIS, 2023).

4. Blockchain i transparentna sledljivost

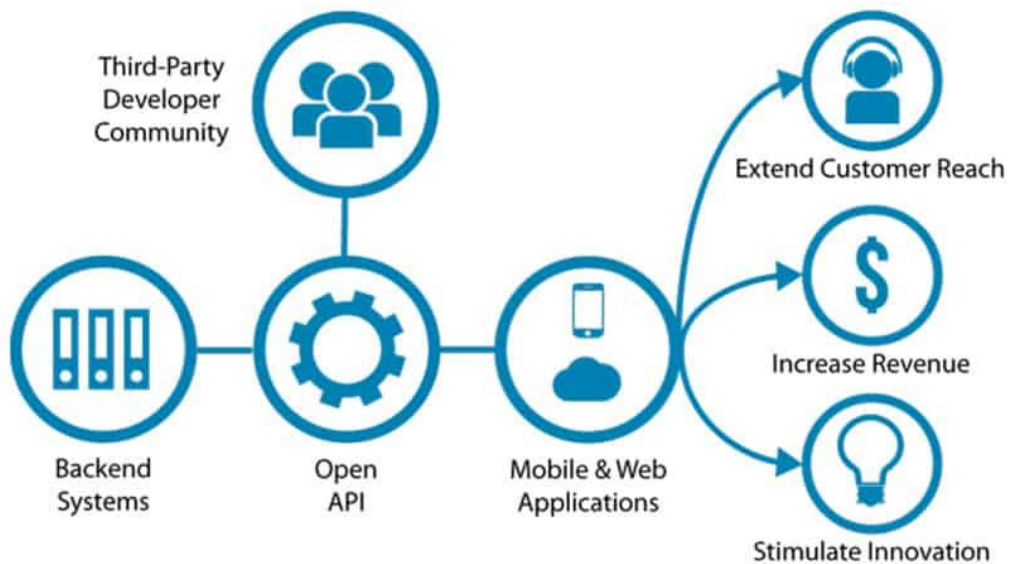
Blockchain tehnologija omogućava beleženje svih aktivnosti u vinogradu - navodnjavanja, tretmana, datuma berbe, korišćene mehanizacije - na nepromenljiv i proverljiv način. Ovakav nivo sledljivosti povećava kredibilitet proizvoda i podržava višu cenu na premium tržištima, uključujući organsku proizvodnju i proizvode sa oznakom geografskog porekla, jer omogućava praćenje proizvoda od vinograda do finalne boce (Kamilaris, 2019).

5. Autonomni i energetski efikasni uređaji

Dugotrajnost i autonomija uređaja na terenu ključni su za održiv sistem. Senzori opremljeni **solarnim panelima**, autonomni LoRa uređaji i integrisana oprema značajno smanjuju troškove održavanja i potrebe za napajanjem. Ovi uređaji su optimizovani za višegodišnji rad bez intervencije, omogućavajući kontinuirano prikupljanje podataka i u izolovanim ili infrastrukturalno slabije razvijenim područjima (Ojha et al., 2015).

5. Univerzalni standardi podataka i otvoreni API interfejsi

Nedostatak interoperabilnosti i dalje predstavlja prepreku u integraciji poljoprivrednih tehnologija. Uvođenje standarda kao što su **ISO SmartAgri** ili **FSIS** (Farm Sensor Interoperability Standard) omogućit će **lakšu razmenu podataka** između senzora, platformi i mehanizacije. Otvoreni API interfejsi dodatno će omogućiti razvoj **modularnih sistema**, smanjujući zavisnost od pojedinačnih dobavljača i povećavajući fleksibilnost za krajnje korisnike (Wolfert et al., 2017).



Slika 31. Struktura API-ja. Izvor: Maplink

7. 7. Strategic evaluation of technology adoption

Usvajanje digitalnih tehnologija u vinogradarstvu predstavlja mnogo više od pukog tehnološkog unapređenja. Ono utiče na strukturu troškova, organizaciju svakodnevnog rada, upravljanje znanjem, sledljivost, kao i na način na koji gazdinstva saraduju sa tehnološkim dobavljačima i ispunjavaju regulatorne zahteve. Zbog toga odluke o investiranju ne bi trebalo da se zasnivaju isključivo na dostupnosti alata ili tržišnim trendovima, već na strateškoj proceni koja povezuje tehnologiju sa stvarnim potrebama, kapacitetima gazdinstva i očekivanim povraćajem.

Institucionalni dokazi i komparativne analize pokazuju da digitalne tehnologije mogu unaprediti produktivnost, održivost i otpornost, ali njihov stvarni efekat zavisi od ključnih uslova: dostupnosti konektivnosti, nivoa ljudskog kapitala, postojanja tehničke podrške, pristupa finansiranju i interoperabilnosti između različitih rešenja (OECD, 2022; European Commission, Joint Research Centre [JRC], 2025). Ukratko, tehnologija sama po sebi ne donosi rezultate – vrednost nastaje tek kada se integriše u radne procese i pretoči u konkretne agronomske i poslovne odluke (OECD, 2022).

Kako bi se evaluacija učinila praktičnom, preporučuje se strukturiranje odluke kroz četiri ključna pitanja. Prvo se odnosi na **vrednost**: koji konkretan benefit se želi postići (efikasnije korišćenje vode, unapređenje kvaliteta, koordinacija berbe, sledljivost, smanjenje klimatskih rizika). Drugo pitanje odnosi se na **ukupne troškove**, koji obuhvataju ne samo cenu nabavke, već i licence, održavanje, zamenu opreme, obuku i vreme potrebno za upravljanje podacima. Treće pitanje tiče se **kapaciteta**: ko će koristiti sistem, ko će interpretirati rezultate, ko će održavati opremu i kakva će spoljašnja podrška biti potrebna. Četvrto pitanje odnosi se na **rizike**, uključujući zavisnost od dobavljača, zastarevanje tehnologije, ograničenja konektivnosti i upravljanje podacima (OECD, 2022; McFadden et al., 2022).

Tabela 1. Praktični okvir za evaluaciju („4 pitanja“)

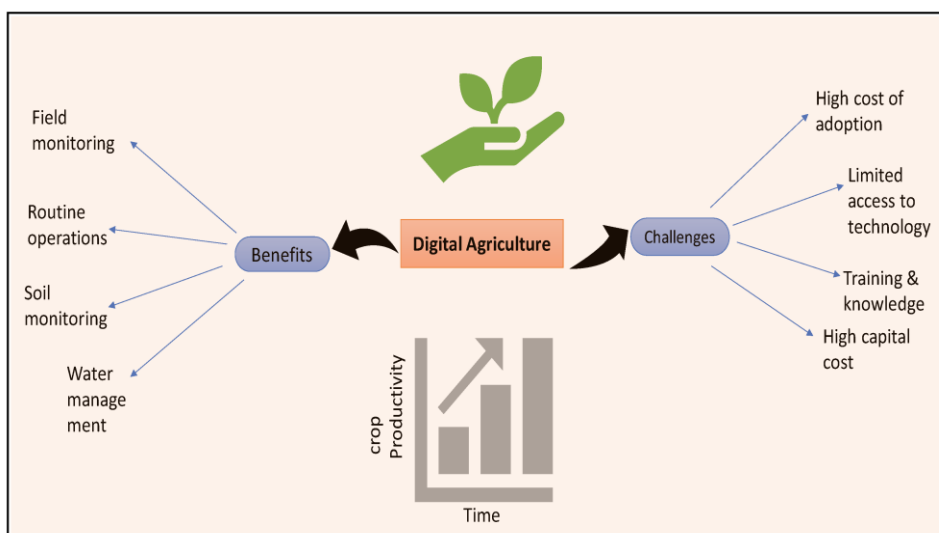
Dimenzija	Ključno pitanje	Šta treba da bude jasno pre investicije
Vrednost	Koje konkretno unapređenje želimo da postignemo?	Operativni indikatori (npr. smanjenje navodnjavanja, ujednačavanje zrenja, unapređenje sledljivosti)
Ukupni trošak	Koliki je stvarni trošak u periodu od 3–5 godina?	Nabavka + instalacija + licence + održavanje + zamene + vreme za upravljanje podacima
Kapaciteti	Ko koristi sistem i ko ga održava?	Uloge, obuka, radne rutine, tehnička podrška, kontinuitet u sezoni vršnog opterećenja
Rizik	Koje zavisnosti sistem uvodi?	Zavisnost od dobavljača, interoperabilnost, vlasništvo nad podacima, konektivnost, sajber bezbednost, zastarevanje tehnologije

7.1. Prednosti i nedostaci digitalnih tehnologija

Svaka inovacija stvara nove mogućnosti, ali istovremeno uvodi i nove zavisnosti i složenost. Razumevanje ove dualnosti ključno je kako bi se izbegle investicije vođene nerealnim očekivanjima ili komercijalnim pritiskom. U poljoprivredi – a posebno kod visokovrednih kultura kao što je grožđe – najveća korist digitalizacije ogleda se u prelasku sa „prosečnih“ odluka („jedna parcela, jedno pravilo“) na odluke zasnovane na stvarnoj varijabilnosti: različitim tipovima zemljišta, mikroklimatskim uslovima, bujnosti ili vodnom statusu unutar iste parcele (OECD, 2022; JRC, 2025).

Jedan od najvažnijih doprinosa digitalnih tehnologija jeste unapređenje donošenja odluka i upravljanja rizicima. Daljinsko osmatranje (sateliti ili UAV) i mape bujnosti ili stresa omogućavaju identifikaciju heterogenosti unutar parcele, praćenje njenog razvoja i usmeravanje intervencija kao što su navodnjavanje, selektivna berba ili prioriteta u operacijama. U vinogradarstvu, stručna literatura potvrđuje da svaka tehnologija ima različit odnos između prostorne rezolucije, učestalosti snimanja i troškova, te izbor optimalnog rešenja zavisi od ciljeva i veličine gazdinstva (Matese et al., 2015). Kada se klimatski, zemljišni i biljni podaci integrišu u DSS sisteme, gazdinstva mogu preciznije odrediti „kada delovati“ i „gde delovati“, čime se smanjuje operativna neizvesnost. OECD ističe da vrednost digitalizacije raste kada se podaci pretvore u konkretne odluke, a ne kada se samo povećava broj indikatora bez jasnog okvira za njihovu interpretaciju (OECD, 2022).

Još jedna značajna prednost jeste efikasnije korišćenje resursa (vode, energije i inputa), uz važnu napomenu: uštede se ostvaruju tek kada je monitoring povezan sa jasnim agronomskim kriterijumima i definisanim protokolima delovanja. Samo praćenje podataka retko donosi rezultate – ključ su odluke i operativne rutine (OECD, 2022). Digitalizacija takođe doprinosi unapređenju sledljivosti i usklađenosti sa standardima, jer omogućava dosledno vođenje evidencije, lakše kontrole i jače dokaze za sertifikaciju, čime donosi ne samo agronomsku, već i komercijalnu i regulatornu vrednost (OECD, 2022).



Slika 32. Šematski prikaz prednosti i izazova digitalizacije u poljoprivredi Izvor: Sejanje održive budućnosti: snalaženje u digitalnom horizontu pametne poljoprivrede

Sa druge strane, analize na nivou Evrope ukazuju na strukturalna ograničenja: nedovoljnu povezanost ruralnih područja, neujednačen nivo digitalnih veština, visoke početne i tekuće troškove, kao i tehnološku fragmentaciju koja otežava objedinjavanje podataka sa različitih platformi (JRC, 2025). Upravljanje podacima dodatno komplikuje situaciju kroz pitanja vlasništva nad podacima, načina njihove upotrebe, sudbine istorijskih skupova podataka i uslova pod kojima se podaci dele ili monetizuju. OECD naglašava da je poverenje u digitalizaciju poljoprivrede ključni preduslov za njenu dugoročnu primenu, posebno kod manjih gazdinstava koja su zabrinuta zbog mogućeg gubitka kontrole nad strateškim informacijama (McFadden et al., 2022).

Tabela 2. Prednosti i ograničenja po tipu tehnologije.

Tehnologija	Najčešće prednosti	Tipična ograničenja
Meteorološke stanice / modeli rizika	Operativno predviđanje; bolje planiranje	Zahteva definisane pragove i protokole reakcije; potrebna konektivnost
Senzori zemljišta/biljke	Precizno podešavanje navodnjavanja; praćenje stresa	Instalacija i kalibracija; održavanje; potreba za tumačenjem podataka
Daljinsko osmatranje (satelit/UAV)	Mape bujnosti; zoniranje; selektivna berba	Kompromis između cene, učestalosti i rezolucije; potrebna terenska validacija
DSS (sistemi za podršku odlučivanju)	Pretvaraju podatke u preporuke; smanjuju neizvesnost	Zavisnost od kvaliteta podataka; mogu delovati kao „crna kutija“ ako se ne razumeju
Digitalni dnevnik / sledljivost	Lakše kontrole; uredna evidencija; usklađenost	Zahteva disciplinovano vođenje evidencije i prilagođavanje radnih rutina

7.2 Troškovi implementacije i održavanja

Iz perspektive proizvođača, ključno pitanje je često ekonomsko: „Da li će mi se ovo isplatiti?“ Javna diskusija uglavnom naglašava koristi, ali komparativne analize pokazuju da mnoge digitalne investicije ne ostvaruju očekivane rezultate jer se potcenjuju tekući troškovi, vreme potrebno za upravljanje i organizacione promene neophodne da bi se alati zaista koristili (OECD, 2022; JRC, 2025). U vinogradarstvu - gde su radovi sezonski, a klimatska neizvesnost visoka - ovo je posebno važno.

Stvarni trošak digitalnog sistema retko se svodi samo na cenu kupovine. Pored nabavke, gazdinstva snose troškove instalacije, kalibracije, konektivnosti, obuke, održavanja, zamene komponenti, pretplata i licenci, kao i vremena potrebnog za prikupljanje, proveru i interpretaciju podataka. Svi ovi elementi zajedno čine ukupni trošak vlasništva (TCO), koji je ključan za procenu isplativosti u realnom vremenskom okviru od 3 do 5 godina (OECD, 2022). Digitalni ekosistem se brzo razvija, pa ažuriranja softvera, promene sistema, novi zahtevi za sajber bezbednost i problemi kompatibilnosti mogu dodatno povećati troškove i smanjiti predvidivost (McFadden et al., 2022).

Često zanemaren aspekt su organizacioni troškovi. Ukoliko gazdinstvo ne definiše jasno ko prati podatke, ko donosi odluke, kada se reaguje i kako se tehnologija uklapa u svakodnevne procese, postoji rizik da sistem ostane

nedovoljno iskorišćen. U praksi, značajan deo troška čini i „trošak učenja“ - vreme potrebno za savladavanje alata, razvoj radnih procedura, podešavanje parametara i proveru rezultata u odnosu na realne uslove na terenu.

Tabela 3. Struktura ukupnog troška vlasništva (TCO) u digitalnim rešenjima u poljoprivredi.

Blok troška	Šta obuhvata	Gde se često potcenjuje
Početna investicija	Uređaji, instalacija, kalibracija	„Gledam samo cenu senzora/platforme“
Operativni troškovi	Pretplate, mobilni internet, energija, potrošni materijal	Mali, ali stalni troškovi koji se akumuliraju
Održavanje	Pregledi, zamene, popravke	Zavisnost od dobavljača i troškovi zastoja
Integracija	Povezivanje sistema, izvoz podataka, tokovi podataka	Interoperabilnost između različitih brendova/platformi
Obuka	Početna i kontinuirana edukacija	Zaposleni uče „u sezoni“, pod pritiskom
Vreme za upravljanje podacima	Pregled upozorenja, validacija podataka, vođenje evidencije	Nedostatak vremena tokom perioda najvećeg opterećenja

7.3 Šta proceniti pre ulaganja u digitalnu tehnologiju

Odluka o investiranju često počinje jednostavnim pitanjem: „Koji konkretan problem želim da rešim? “. Međunarodna istraživanja dosledno pokazuju da uspešne implementacije polaze od analize proizvodnje i organizacije, a ne od same tehnologije; kada se tehnologija kupuje bez jasne operativne svrhe, veća je verovatnoća da će biti napuštena (OECD, 2022; JRC, 2025).

U vinogradarstvu, ciljevi se najčešće grupišu u četiri kategorije. Prvo, ciljevi efikasnosti (voda, energija, inputi). Drugo, ciljevi kvaliteta (zoniranje, selektivna berba, ujednačeno sazrevanje). Treće, ciljevi usklađenosti i sledljivosti. Četvrto, ciljevi upravljanja rizikom (klimatski uslovi, bolesti, operativna neizvesnost). Jasno definisanje dominantnog cilja je ključno, jer svaki od njih zahteva različite tehnologije i nivoe složenosti. Na primer, meteorološka stanica i sistemi upozorenja mogu biti presudni za upravljanje rizikom od bolesti; mreže senzora i mapiranje su opravdaniji u premium strategijama; dok digitalni dnevnik može rešiti veliki deo administrativnih i regulatornih zahteva.

Nakon definisanja cilja, drugi kriterijum je stvarna varijabilnost vinograda. Precizna poljoprivreda donosi najveću vrednost tamo gde postoje značajne razlike unutar parcele; u ujednačenim vinogradima, poslovni razlozi za digitalizaciju češće se nalaze u oblasti usklađenosti, logistike i pojednostavljenja administracije (OECD, 2022). Treći kriterijum

odnosi se na ljudski faktor: raspoložive veštine i vreme. Evropska unija naglašava kontinuiranu obuku i savetodavne usluge kao ključne za održivu digitalizaciju; bez adekvatne podrške, čak i dobro odabrana rešenja mogu propasti jer se ne integrišu u svakodnevne radne procese (EU CAP Network, 2024).

Tabela 4. Matrica proporcionalnosti: „potreba-kapacitet-rešenje“

Profil gazdinstva	Primarna potreba	Interni kapacitet	Proporcionalni digitalni pristup
Malo/porodično	Upozorenja i planiranje; pojednostavljenje evidencije	Ograničen	Osnovna rešenja + ciljane spoljne usluge
Srednje, orijentisano na kvalitet	Zoniranje, selektivna berba, sledljivost	Umeren	Senzori/daljinsko osmatranje + DSS uz tehničku podršku
Zadruga / više proizvođača	Koordinacija, ujednačenost, sledljivost	Varijabilan	Zajedničke platforme + obuka + zajednički protokoli
Veliko/intenzivno	Optimizacija na velikom obimu i logistika	Visok	Integracija podataka + postepena automatizacija

7.4 Modeli postepenog usvajanja digitalne tehnologije

Digitalna transformacija se retko dešava u jednom koraku. Komparativne analize pokazuju da se najuspešniji procesi razvijaju postepeno, kroz sticanje iskustva, izgradnju internog poverenja i evaluaciju rezultata pre daljeg širenja (OECD, 2022). Ovakav pristup je posebno značajan u vinogradarstvu, gde klimatska neizvesnost i varijabilnost prihoda čine smanjenje rizika racionalnim izborom.

U praksi, mnogi vinogradi započinju sa „osnovnim nivoom“ digitalizacije: vođenjem evidencije, praćenjem vremenskih uslova i sistemima upozorenja. Zatim uvode monitoring (senzore i mape), a u završnoj fazi prelaze na integrisane sisteme (DSS i delimičnu automatizaciju). Ovakav slojeviti pristup omogućava paralelan razvoj kapaciteta uz postepeno povećanje složenosti sistema. Pored toga, modeli zasnovani na uslugama (npr. plaćanje po korišćenju dronova ili analiza) i kooperativni modeli (zajednička infrastruktura i savetodavni kapaciteti) mogu smanjiti finansijske barijere i ubrzati kolektivno učenje, u skladu sa evropskim pristupom koji naglašava obuku i mreže inovacija u poljoprivredi (EU CAP Network, 2024).

Tabela 5. Modeli postepenog usvajanja i uslovi u kojima daju najbolje rezultate

Ruta	Opis	Kada je najpogodnija
Ograničeni pilot	Testiranje na jednoj parceli ili u jednoj sezoni	Kada je ROI ili upotrebljivost neizvesna
Spoljne usluge	Plaćanje po korišćenju (dronovi, analize, savetovanje)	Mala i srednja gazdinstva sa retkom upotrebom
Kooperativni/zajednički model	Deljena infrastruktura i podrška	Regioni sa mnogo proizvođača i ograničenim resursima
Postepeno usvajanje	Od osnovnog ka integrisanom u periodu od 2–4 godine	Kada su dugoročna održivost i učenje prioritet

Literatura

- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). Evapotranspiracija useva: Smernice za izračunavanje potreba za vodom kod useva. *FAO Irrigation and Drainage Paper* 56.
- Ammoniaci, M., Kartsiotis, S.-P., Perria, R., & Storchi, P. (2021). Savremeno stanje tehnologija monitoringa i obrade podataka u preciznom vinogradarstvu. *Agriculture*, 11(3), 201. <https://doi.org/10.3390/agriculture11030201>
- Aqeel-your-Rehman, Abbasi, A. Z., Islam, N., & Shaikh, Z. A. (2014). Pregled primene bežičnih senzora i mreža u poljoprivredi. *Computer Standards & Interfaces*, 36(2), 263–270. <https://doi.org/10.1016/j.csi.2011.03.001>
- Ayaz, M., Shehzad, N., Ahmad, I., & Sharif, K. (2019). Automatizovana detekcija biljnih bolesti primenom mašinskog učenja. *Big Data and Cognitive Computing*, 3(2), 26. <https://doi.org/10.3390/bdcc3020026>
- Basile, K., et al. (2023). Modeli fenologije zasnovani na dubokom učenju za satelitsko praćenje vinove loze. *Ives OpenScience*.
- Bindi, M., & Olesen, J. E. (2011). Reakcije poljoprivrede u Evropi na klimatske promene. *Regional Environmental Change*, 11(1), S151–S158. <https://doi.org/10.1007/s10113-010-0173-x>
- Bongiovanni, R., & Lowenberg-DeBoer, J. (2004). Precizna poljoprivreda i održivost. *Precision Agriculture*, 5(4), 359–387. <https://doi.org/10.1023/B:PRAG.0000040806.39604.aa>
- Bramley, R. G. V. (2009). Pouke iz skoro 20 godina istraživanja preciznog vinogradarstva u Australiji. *Australian Journal of Grape and Wine Research*, 15(1), 131–139. <https://doi.org/10.1111/j.1755-0238.2009.00049.x>
- Bramley, R. G. V., & Hamilton, R. P. (2007). Razumevanje varijabilnosti u proizvodnji vinskog grožđa. *Australian Journal of Grape and Wine Research*, 13(1), 32–45. <https://doi.org/10.1111/j.1755-0238.2006.tb00039.x>
- Broome, J. C., English, J. T., & Marois, J. J. (1995). Razvoj modela infekcije za sivu trulež grožđa (*Botrytis*) na osnovu temperature i trajanja vlaženja. *Phytopathology*, 85(1), 97–102. <https://doi.org/10.1094/Phyto-85-97>
- Burrell, J., Brooke, T., & Beckwith, R. (2004). Računarstvo u vinogradima: mreže senzora u poljoprivrednoj proizvodnji. *IEEE Pervasive Computing*, 3(1), 38–45. <https://doi.org/10.1109/MPRV.2004.1269130>
- Calonnec, A., Cartolaro, P., & Dubourdieu, D. (2008). Modelovanje razvoja bolesti i procena uticaja strategija kontrole pepelnice kod vinove loze. *Plant Pathology*, 57(3), 493–508.
- Carmona, J. A., Tardaguila, J., & Diago, M. P. (2021). Predviđanje prinosa vinove loze i kvaliteta grožđa primenom mašinskog učenja i UAV snimaka. *Computers and Electronics in Agriculture*, 187, 106269. <https://doi.org/10.1016/j.compag.2021.106269>
- Castro, F., Sosa, A., & Carballo, J. (2021). Varijabilna primena đubriva u vinogradarstvu korišćenjem mapa azota dobijenih dronovima: studija slučaja u Mendози, Argentina. *Precision Agriculture*, 22(4), 973–990. <https://doi.org/10.1007/s11119-020-09750-1>

- Chuine, I., Bonhomme, M., Legave, J. M., García de Cortázar-Atauri, I., Charrier, G., & Lacoite, A. (2013). Da li fenološki modeli mogu tačno predvideti fenologiju biljaka u budućnosti? *Global Change Biology*, 22(10), 3444–3460.
- CORDIS. (2020). VINTAGE – sažetak projekta preciznog vinogradarstva. EU Research Results. <https://cordis.europa.eu/project/id/226783>
- CORDIS. (2023). AI-GRAPE: Praćenje zdravlja vinove loze zasnovano na veštačkoj inteligenciji. EU H2020 Projects Database. <https://cordis.europa.eu/project/id/101060840>
- Delmotte, F., Corio-Costet, M. F., & Delière, L. (2020). Integrisano upravljanje bolestima i smanjenje upotrebe pesticida u vinogradarstvu: evaluacija sistema za podršku odlučivanju. *Science of the Total Environment*, 731, 139269. <https://doi.org/10.1016/j.scitotenv.2020.139269>
- Di Gennaro, S. F., Matese, A., & Vaccari, F. P. (2020). Napredne tehnike daljinskog osmatranja i vizualizacije u preciznom vinogradarstvu. *Agronomy*, 10(7), 967. <https://doi.org/10.3390/agronomy10070967>
- Elsherbiny, O.; Elaraby, A.; Alahmadi, M.; Hamdan, M.; Gao, J. (2024). Brza dijagnostika zdravlja vinove loze zasnovana na digitalnom snimanju i dubokom učenju. *Plants (Basel)*, 13(1), 135. <https://doi.org/10.3390/plants13010135>
- Fernandes, J. P., Silva, L., Gomes, M., & Oliveira, T. (2022). Predviđanje prinosa vinove loze korišćenjem vremenskih serija Sentinel-2 i LSTM neuronskih mreža: studija slučaja u regionu Alto Douro. *Remote Sensing*, 14(18), 4591. <https://doi.org/10.3390/rs14184591>
- Finger, R., Swinton, S. M., El Benni, N., & Walter, A. (2019). Precizna poljoprivreda na preseku proizvodnje i zaštite životne sredine. *Annual Review of Resource Economics*, 11, 313–335. <https://doi.org/10.1146/annurev-resource-100518-093929>
- García, M., Hernández, L., & Santesteban, L. G. (2022). Digitalni blizanci u vinogradarstvu: integracija podataka u realnom vremenu za dinamičko modelovanje. *Agronomy*, 12(4), 856.
- Gubler, W. D., Rademacher, M. R., & Vasquez, S. J. (1999). Kontrola pepelnice korišćenjem UC Davis indeksa rizika. *California Agriculture*, 53(1), 14–19. <https://doi.org/10.3733/ca.v053n01p14>
- Huang, Y., Wang, H., & Fuentes, S. (2022). Identifikacija bolesti listova vinove loze primenom dubokog učenja i UAV multispektralnih snimaka. *Remote Sensing*, 14(12), 2803. <https://doi.org/10.3390/rs14122803>
- Kamilaris, A., Kartakoullis, A., & Prenafeta-Boldú, F. X. (2019). Blockchain u poljoprivredi: sistematski pregled. *Agronomy*, 9(10), 18. <https://doi.org/10.3390/agronomy9100661>
- Kerkech, M., Hafiane, A., & Canals, R. (2020). Detekcija bolesti vinove loze primenom dubokog učenja i vegetacionih indeksa. *Computers and Electronics in Agriculture*, 175, 105528. <https://doi.org/10.1016/j.compag.2020.105528>
- Martínez-Casasnovas, J. A., Escolà, A., & Ramos, M. C. (2012). Zone upravljanja u preciznom vinogradarstvu: pregled. *Precision Agriculture*, 13(5), 622–638. <https://doi.org/10.1007/s11119-012-9272-6>

- Matese, A., & Di Gennaro (2015). Tehnologije u preciznom vinogradarstvu: pregled stanja. *International Journal of Wine Research*, 7, 69–81. <https://doi.org/10.2147/IJWR.S69405>
- Ojha, T., Misra, S., & Raghuwanshi, N. S. (2015). Bežične senzorske mreže u poljoprivredi: stanje i budući izazovi. *Computers and Electronics in Agriculture*, 118, 66–84. <https://doi.org/10.1016/j.compag.2015.08.011>
- Rossi, V., Caffi, T., & Salinari, F. (2012). Pomoć poljoprivrednicima u suočavanju sa složenim odlukama u zaštiti bilja. *Phytopathologia Mediterranea*, 51, 457–479. https://doi.org/10.14601/Phytopathol_Mediterr-11038
- Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Praćenje vegetacije u Velikim ravninama pomoću ERTS sistema. *NASA Special Publication*, 351, 309.
- Santesteban, L. G., et al. (2017). Varijabilnost vinograda i digitalno vinogradarstvo: trenutno stanje i buduće perspektive. *Frontiers in Plant Science*, 8, 660. <https://doi.org/10.3389/fpls.2017.00660>
- Tisseyre, B., Ojeda, H., & Taylor, J. A. (2011). Nove tehnologije i metodologije za precizno vinogradarstvo. *OENO One*, 45(3), 123–134. <https://doi.org/10.20870/oenone.2011.45.3.1507>
- Ünal, Z. (2020). Pametna poljoprivreda postaje još pametnija uz duboko učenje – bibliografska analiza. *IEEE Access*, 8, 105587–105609. <https://doi.org/10.1109/ACCESS.2020.3000175>
- Verdouw, C. N., Tekinerdogan, B., Beulens, A. J. M., & Wolfert, J. (2021). Digitalni blizanci u pametnoj poljoprivredi. *Agricultural Systems*, 189, 103046. <https://doi.org/10.1016/j.agry.2020.103046>
- VineSens. (2020). Pametni sistem za monitoring vinograda. <https://www.vine-sens.com>
- Wolfert, S., Ge, L., Verdouw, C., & Bogaardt, M. J. (2017). Veliki podaci u pametnoj poljoprivredi i- pregled. *Agricultural Systems*, 153, 69–80. <https://doi.org/10.1016/j.agry.2017.01.023>

ANEKS I – Pitanja za proveru znanja

Blok 1: Uvod u precizno vinogradarstvo

1. Objasnite sopstvenim rečima šta znači „varijabilnost unutar parcele“ i zašto njeno zanemarivanje dovodi do neefikasnog i manje održivog upravljanja.
2. Uporedite dve ekološke i dve proizvodne koristi upravljanja zonama specifičnog upravljanja (SEZ).
3. Opišite minimalni tok procesa (u 5 koraka) od posmatranja vinograda do odluke o sektorskom navodnjavanju.

4. Izaberite jedan faktor (zemljište, klima, nagib ili osunčanost) i objasnite kako može na različite načine uticati na bujnost, prinos i kvalitet unutar iste parcele.
5. Kratak slučaj: vinarija prijavljuje uštedu vode od 30–40% nakon sektorizacije navodnjavanja. Koji podaci su neophodni da bi se ovaj rezultat potvrdio i izbegle greške u tumačenju?

Blok 2: Vizualizacija podataka i prediktivno modelovanje u upravljanju vinogradom

6. 6. Razlikujte pojmove „podatak“, „informacija“ i „znanje“ koristeći primer NDVI, vlažnosti zemljišta i odluke o berbi.
7. Objasnite prednosti i ograničenja primene neuronskih mreža za predviđanje prinosa u odnosu na jednostavnije metode (npr. linearna regresija).
8. Šta znače „validacija“ i „generalizacija“ modela u vinogradarstvu? Predložite osnovni protokol unakrsne validacije između proizvodnih sezona.
9. Navedite primer kada „naizgled jasna“ vizualizacija dovodi do pogrešne odluke. Kako biste to izbegli?

Blok 3: Pametne tehnologije monitoringa u vinogradu

10. Uporedite senzore zemljišta i lisne/sokne senzore: šta mere, kada se koriste i kako se međusobno dopunjuju.
11. Objasnite kako dobro dizajnirana WSN mreža (LoRaWAN/Zigbee) pomaže u predviđanju mraza ili vodnog stresa.
12. Razlikujte upotrebu satelita (pokrivenost, učestalost) i dronova (rezolucija, pravovremenost) u upravljanju unutar parcele
13. Koje greške u interoperabilnosti se najčešće javljaju između GIS sistema i mehanizacije? Predložite rešenja.
14. Uporedite očekivani uticaj na životnu sredinu između VRT tehnologije i uniformnog upravljanja u pogledu vode, azota i fungicida.

Blok 4: Sistemi za podršku odlučivanju (DSS)

15. Opišite tok rada DSS sistema u vinogradu od prikupljanja podataka do akcije (6 faza).
16. Razradite primer u kome DSS preporučuje navodnjavanje u ZME-3: koji ulazni podaci ga aktiviraju, a koji uslovi ga sprečavaju?
17. Kako biste uveli kontinuirano učenje DSS sistema nakon svake proizvodne sezone? Navedite najmanje 3 parametra koja biste prilagođavali.
18. Dizajnirajte ekran mobilne aplikacije za operatere u vinogradu: šta treba da prikazuje, koje notifikacije i koje brze akcije.

Blok 5: Izazovi, ljudi i modeli usvajanja tehnologije

19. Identifikujte tri ljudske/kulturne prepreke digitalizaciji i načine njihovog prevazilaženja kroz obuku i liderstvo.

- 20. Uporedite kupovinu opreme i SaaS/usluge: rizici, tekući troškovi i fleksibilnost.**
- 21. Kako biste prioritizovali ulaganja između meteorološke stanice, senzora zemljišta, dronova i VRT tehnologije na gazdinstvu sa ograničenim budžetom?**
- 22. Predstavite primer saradničkog modela (deljenje dronova/analitike u okviru zadruge ili DO): pravila i koristi.**

ANEKS II – Didaktička aktivnost: „Izbor odgovarajućih tehnologija za dve vinarije sa sličnim problemima“

Cilj ove aktivnosti je da vam pomogne da strateški razmišljate o usvajanju digitalnih tehnologija u vinogradarstvu.

Analiziraćete dve vinarije koje se suočavaju sa sličnim agronomskim izazovima, ali se značajno razlikuju po veličini, finansijskim kapacitetima i internim resursima.

Vaš zadatak je da predložite realistična i proporcionalna tehnološka rešenja za svaku vinariju.

Obe vinarije imaju sledeće ponavljajuće probleme:

- Neujednačena bujnost vinove loze unutar vinograda.
- Vodni stres tokom letnjih toplotnih talasa.
- Pojava bolesti (posebno pepelnice) nakon vlažnih noći.
- Neujednačeno sazrevanje, što otežava organizaciju berbe
- Pritisak da se smanji upotreba inputa (voda, azot, fungicidi) bez smanjenja prinosa ili kvaliteta.

Razlika između ova dva slučaja nije u problem - već u njihovom kapacitetu za ulaganje i upravljanje tehnologijom.

Vinarija A – Velika i finansijski snažna

- 220 hektara raspoređenih na više lokacija.
- Tim stručnjaka zaposlenih puno radno vreme i menadžer vinograda.
- Pristup IT podršci (interna ili eksternalizovana).
- Visok finansijski kapacitet.
- Glavni izazov: koordinacija i ujednačenost između velikog broja parcela.

Vinarija B – Mala i ograničenih resursa

- 18 hektara, uglavnom u kontinuitetu.
- Vlasnik upravlja proizvodnjom, uz 1–2 sezonska radnika.
- Ograničeno vreme za administraciju.
- Ograničen finansijski kapacitet.

- Glavni izazov: upravljanje vremenom i jednostavni alati za donošenje odluka.

Možete birati iz sledećeg „menija“ tehnologija:

1. Digitalni dnevnik polja / aplikacija za sledljivost
2. Meteorološka stanica sa mobilnim upozorenjima
3. Satelitske mape bujnosti (osnovni monitoring servis)
4. Dron monitoring (outsourcing letova)
5. Senzori vlažnosti zemljišta
6. Podrška za planiranje navodnjavanja (aplikacija ili savetovanje)
7. DSS (sistem za podršku odlučivanju) za navodnjavanje ili bolesti
8. Oprema za varijabilnu primenu
9. Alat za komunikaciju i planiranje tima
10. Eksterni agronomski savetodavni ugovor Digital field notebook / traceability app

Nije potrebno da koristite tehničke proračune.

Fokus je na strateškom razmišljanju, proporcionalnosti i izvodljivosti.

Zadaci

1. Izbor tehnologije (osnovni zadatak)

Za svaku vinariju:

- Izaberite tri tehnologije za implementaciju tokom prve godine.
- Jasno obrazložite svoj izbor.

Obrazloženje treba da objasni:

- Zašto ova tehnologija odgovara veličini i ekonomskom kapacitetu vinarije.
- Kako rešava zajedničke agronomске probleme.
- Zašto je realno implementirati je u jednoj vegetacionoj sezoni.
- Zašto nisu izabrane složenije ili skuplje alternative.

2 Definišite četiri KPI-ja za svaku vinariju

Za svaku vinariju definišite četiri ključna indikatora performansi (KPI) koji se mogu meriti na kraju sezone.

KPI treba da budu:

KPIs should be:

- Jednostavni
- Merljivi
- Realni za jednu godinu

Primeri (možete ih prilagoditi ili osmisliti nove):

- % smanjenja potrošnje vode za navodnjavanje
- Manji broj uniformnih tretmana fungicidima
- Poboljšana ujednačenost sazrevanja
- Manji broj kasnih intervencija zbog bolesti
- Smanjenje administrativnog vremena
- Bolja koordinacija berbe

Ukratko objasnite zašto je svaki KPI relevantan.

3. Opišite proces „Podatak → Odluka → Akcija“

Za svaku vinariju opišite:

- Jedan proces donošenja odluke za navodnjavanje
- Jedan proces donošenja odluke za zaštitu od bolesti

Objasnite:

- Koji podaci se prikupljaju
- Ko ih analizira
- Kako se donosi konačna odluka
- Koja se akcija sprovodi u vinogradu

Nisu potrebni tehnički dijagrami. Dovoljan je jasan opis.

4. Identifikacija rizika i mere ublažavanja

Za svaku vinariju:

- Identifikujte dva realna rizika vezana za usvajanje tehnologije.
- Predložite jednu meru ublažavanja za svaki rizik.

Primeri rizika:

- Preopterećenost zaposlenih
- Troškovi pretplate
- Nedostatak digitalnih veština
- Prevelika zavisnost od jednog dobavljača
- Nedosledna upotreba tehnologije

5. Plan komunikacije

Objasnite kako će se rezultati komunicirati:

- **Menadžmentu (ekonomska i strateška perspektiva)**
- **Timu u vinogradu (operativna perspektiva)**

Budite konkretni i praktični.